

UNIVERZITA KARLOVA V PRAZE

Přírodovědecká fakulta

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie

Studijní obor: Geografie a kartografie



Lucie Jakešová

**MOŽNOSTI OBJEKTOVĚ-ORIENTOVANÉ
KLASIFIKACE PRO URČOVÁNÍ VYBRANÝCH BIOTOPŮ
NAD HORNÍ HRANICÍ LESA V KRKONOŠSKÉM
NÁRODNÍM PARKU**

**POSSIBILITIES OF OBJECT-BASED CLASSIFICATION FOR
SELECTED BIOTOPES ABOVE TREE-LINE IN THE KRKONOŠE
MTS. NATIONAL PARK DETECTION**

Bakalářská práce

Vedoucí bakalářské práce: Mgr. Lucie Červená

Konzultantka: RNDr. Lucie Kupková, Ph.D.

Praha, 2014

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci zpracovala samostatně a že jsem uvedla všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

Jsem si vědoma toho, že případné použití výsledků, získaných v této práci, mimo Univerzitu Karlovu v Praze je možné pouze po písemném souhlasu této univerzity.

Svoluji k zapůjčení této práce pro studijní účely a souhlasím s tím, aby byla řádně vedena v evidenci vypůjčovatelů.

V Praze dne 20. 8. 2014

.....

Lucie Jakešová

Poděkování

Ráda bych tímto poděkovala vedoucí mé práce Mgr. Lucii Červené za věnovaný čas, cenné rady a připomínky, konzultantce RNDr. Lucii Kupkové, Ph.D za uvedení do problematiky. Dále RNDr. Stanislavovi Březinovi, Ph.D. a Mgr. Janovi Šturmovi za pomoc a věnovaný čas při terénním průzkumu. V neposlední řadě společnosti ARCDATA PRAHA s.r.o. za zapůjčení licence k softwaru ENVI 5.1, zejména Mgr. Lucii Patkové za její zprostředkování.

Možnosti objektově-orientované klasifikace pro určování vybraných biotopů nad horní hranicí lesa v Krkonošském národním parku

Abstrakt

Bakalářská práce je zaměřena na objektově-orientovanou klasifikaci vegetace nad horní hranicí lesa v Krkonošském národním parku s využitím ortofota s blízkým infračerveným pásmem a prostorovým rozlišením 12,5 cm. Ortofoto bylo pořízeno v létě roku 2012. Legenda vegetace byla vytvořena botanikem z Krkonošského národního parku. Objektově-orientovaná klasifikace na základě dat z terénu proběhla v softwaru ENVI 5.1, který nabízí dva přístupy klasifikace – *Example-based* a *Rule-based*. Tyto dva přístupy byly porovnány a jako lepší pro danou problematiku se jeví *Example-based*. Nejlepší výsledek klasifikace dosáhl celkové přesnosti 75,97 % pro 13 tříd.

Klíčová slova: objektová klasifikace, KRNAP, vegetace nad horní hranicí lesa, optický letecký skener

Possibilities of object-based classification for selected biotopes above tree-line in the Krkonoše Mts. National Park detection

Abstract

The bachelor thesis is focused on the object-based classification of vegetation above the tree-line in the Krkonoše Mts. National Park using orthophoto with near infrared band and spatial resolution of 12.5 cm. Orthophoto was acquired in summer 2012. The classification legend was compiled by botanist of the national park. Software ENVI 5.1 was used for object-based classification using the field data. It provides two approaches to classification – *Example-based* and *Rule-based*. The overall accuracy of the best classification result was 75.97 % for 13 classes.

Keywords: object-based classification, KRNAP, biotopes above tree-line, aerial optical scanner

Obsah

Seznam obrázků a tabulek	7
Seznam použitých zkratk	9
1 Úvod a cíle práce	10
2 Literární rešerše a úvod do problematiky	11
2.1 Klasifikace vegetace.....	12
2.2 Klasifikace vegetace nad horní hranicí lesa	14
2.3 Objektová klasifikace.....	17
2.3.1 Segmentační algoritmy v ENVI.....	17
2.3.2 Klasifikace <i>Example-based</i>	19
2.3.3 Klasifikace <i>Rule-based</i>	20
2.4 Support Vector Machine (SVM).....	20
3 Charakteristika zájmového území	22
3.1 Arkto-alpínská tundra Krkonoš.....	22
4 Data a Metodika	24
4.1 Legenda vegetace nad horní hranicí lesa	24
4.2 Použitá data	36
4.2.1 Data z leteckého optického skeneru.....	36
4.2.2 DEM, DSM.....	36
4.2.3 Terénní data	37
4.3 Předzpracování dat	38
4.3.1 Vegetační indexy	39
4.3.2 Masky vegetace nad horní hranicí lesa	40
4.4 Objektová klasifikace <i>Example-based</i>	41
4.5 Objektová klasifikace <i>Rule-based</i>	42
5 Výsledky.....	45
5.1 Hodnocení přesnosti.....	45
5.2 Grafické výstupy	47
6 Diskuze	50
7 Závěr.....	53
Použitá literatura	54
Seznam příloh	57

Seznam obrázků a tabulek

<i>Obr. 1: Označení všech segmentů, které protne trénovací plocha</i>	19
<i>Obr. 2: Označení segmentu, do kterého spadne těžiště trénovací plochy</i>	19
<i>Obr. 3: Klasifikační pravidla (Exelis VIS, 2014b, upravené autorkou)</i>	20
<i>Obr. 4: Kosodřevina (foto: Lucie Červená)</i>	25
<i>Obr. 5: Rašeliniště (foto: Lucie Červená)</i>	26
<i>Obr. 6: Mokřad – ostatní (foto: Lucie Červená)</i>	27
<i>Obr. 7: Vodní plocha (foto: Lucie Červená)</i>	27
<i>Obr. 8: Alpínská vřesoviště (foto: Lucie Červená)</i>	28
<i>Obr. 9: Subalpínská brusnicová vegetace (foto: Lucie Červená)</i>	29
<i>Obr. 10: Smilka (foto: Lucie Červená)</i>	30
<i>Obr. 11: Metlička (foto: Lucie Červená)</i>	30
<i>Obr. 12: Druhově bohaté porosty s velkým zastoupením dvouděložných (foto: Lucie Červená)</i>	31
<i>Obr. 13: Třtina (foto: Lucie Červená)</i>	32
<i>Obr. 14: Bezkolnec (foto: Lucie Červená)</i>	33
<i>Obr. 15: Metlice (foto: Lucie Červená)</i>	33
<i>Obr. 16: Subalpínské vysokobylinné trávníky (foto: Lucie Červená)</i>	34
<i>Obr. 17: Ukázky spekter jednotlivých kategorií naměřených v terénu spektrometrem ASD FieldSpec 4 Wide-Res a kontaktní sondou</i>	35
<i>Obr. 18: Ukázka jednotlivých modelů</i>	36
<i>Obr. 19: Rozdělení polygonů na trénovací a validační</i>	38
<i>Obr. 20: Výřez zájmového území</i>	39
<i>Obr. 21: Maska vegetace nad horní hranicí lesa</i>	41
<i>Obr. 22: Segmentace snímku pro Example-based klasifikaci</i>	42
<i>Obr. 23: Segmentace snímku Rule-based klasifikace pro oddělení kategorie 1 a 2</i>	43
<i>Obr. 24: Výsledek objektové klasifikace pomocí přístupu Example-based</i>	48
<i>Obr. 25: Výsledek objektové klasifikace pomocí přístupu Rule-based</i>	49
<i>Tab. 1: Rozlohy a poměry trénovacích a validačních polygonů</i>	37
<i>Tab. 2: Seznam použitých indexů</i>	40
<i>Tab. 3: Použitá pravidla a atributy masky vegetace nad horní hranicí lesa</i>	41

<i>Tab. 4: Použitá pravidla a atributy pro Rule-based klasifikaci kategorií 1 a 9</i>	<i>43</i>
<i>Tab. 5: Použitá pravidla a atributy zbylých kategorií legendy.....</i>	<i>44</i>
<i>Tab. 6: Přesnosti a kappa koeficient klasifikace Example-based.....</i>	<i>46</i>
<i>Tab. 7: Přesnosti a kappa koeficient klasifikace Rule-based</i>	<i>46</i>

Seznam použitých zkratk

DAIS	Digital Airborne Imaging System
DEM	Digital Elevation Model
DPZ	Dálkový Průzkum Země
DSM	Digital Surface Model
GB	Gigabyte
GPS	Global Positioning System
GRDI	Green Red Difference Index
IHS	Intensity Hue Saturation color space
ISODATA	Iterative Self-Organizing Data Analysis Technique
KNN	K Nearest Neighbor
KRNAP	Krkonošský národní park
Landsat 7 ETM+	Landsat 7 Enhanced Thematic Mapper Plus
Landsat TM	Landsat Thematic Mapper
NDVI	Normalized Difference Vegetation Index
NIR	Near Infrared band
PCA	Principal Component Analysis
RGB	Red Green Blue color model
ROSIS	Reflective Optics System Imaging Spectrometer
RVI	Ratio Vegetation Index
SR	Simple Ratio
STD	Standard Deviation
SVM	Support Vector Machine

1 Úvod a cíle práce

Vegetace nad horní hranicí lesa (nad 1 300 m n. m.) je jedinečný ekosystém, který se vyznačuje mozaikou podhorských luk s převažující smilkou tuhou (*Nardus stricta*) a borovicí klečí (*Pinus mugo*), dále se zde vyskytují subalpínská rašeliniště, skály a v nejvyšších polohách krkonošské tundry nalezneme bohaté druhy lišejníků. Zároveň zde dochází k prolínání severské a alpínské tundry.

Hlavním cílem této bakalářské práce je testování využitelnosti objektově-orientované klasifikace při klasifikaci vegetace nad horní hranicí lesa v modelovém území Krkonošského národního parku. Pro klasifikaci budou použita ortofota se čtyřmi spektrálními pásmy (červené, zelené, modré a blízké infračervené) a s vysokým prostorovým rozlišením 12,5 cm. Klasifikace bude provedena na základě legendy stanovené botanikem z Krkonošského národního parku.

Dalším cílem je zhodnocení, s jakou přesností je možné tímto způsobem klasifikovat jednotlivé kategorie stanovené legendy a případný návrh na úpravu legendy. Hodnocení přesnosti bude provedeno pomocí chybové matice na základě kontrolních ploch nasbíraných v terénu opět ve spolupráci s botanikem z Krkonošského národního parku pomocí GPS přístroje s decimetrovou přesností. Také budou porovnány dva různé přístupy k objektové klasifikaci v softwaru ENVI 5.1, balíčku *Feature extraction (Example-based a Rule-based)*.

Nedílnou součástí práce je také rešerše literatury, která se týká klasifikací land cover nad horní hranicí lesa a objektově-orientované klasifikace. Výsledky objektově-orientované klasifikace ortofot s vysokým prostorovým rozlišením budou následně srovnány s výsledky Müllerové (2005), která použila metodu řízené klasifikace maximum likelihood a ortofota s prostorovým rozlišením 1 m.

2 Literární rešerše a úvod do problematiky

V případě nižšího prostorového rozlišení snímků, kdy velikost pixelů je větší nebo podobná velikosti objektů zájmu, se pro klasifikaci obrazu používá pixelová klasifikace (per-pixel). U této metody je základní jednotkou zařazovanou do klasifikačních tříd obrazový prvek (pixel), který je zařazován pouze na základě spektrálních vlastností. Se zvyšujícím se prostorovým rozlišením snímků je vhodnější použít metodu objektově orientované analýzy obrazu. Klasifikace založená pouze na spektrálních vlastnostech pixelu je tak pro některé úlohy nedostačující a nepřesná (Blaschke, 2010). V objektové klasifikaci se kromě spektrálních příznaků využívají také příznaky kontextuální, tvarové či geometrické (Yu et al., 2006).

Porovnáním objektové a pixelové klasifikace se ve své práci zabýval Yu et al. (2006) při klasifikaci vegetace v Severní Kalifornii. Zájmové území s rozlohou 72,845 ha se skládalo z 26 leteckých snímků s prostorovým rozlišením 1 m. Snímky obsahovaly čtyři pásma: modré (0,45-0,53 μm), zelené (0,52-0,61 μm), červené (0,64-0,72 μm) a blízké infračervené (0,77-0,88 μm). Legenda zahrnovala 43 vegetačních tříd, které byly navrženy na základě databáze California Native Plant Society, a 5 tříd neobsahujících vegetaci (voda, duny, pláže, městská zástavba a holá půda). Z výsledků vyplývá, že metodou objektové klasifikace se eliminuje efekt osamocených pixelů (tzv. salt and pepper effect), a výstup je o 17 % přesnější než výstup z klasifikace pixelové. Obdobných výsledků dosáhl i Cleve et al. (2008) při klasifikaci městské zástavby. Pro klasifikaci použil letecké snímky se třemi pásmy (červené, zelené a modré) a prostorovým rozlišením 15 cm. Na základě snímků byly stanoveny čtyři klasifikační kategorie (zastavěná plocha, stromy a keře, nízká vegetace a stíny). Pixelová klasifikace dosáhla celkové přesnosti 62,17 %, zatímco objektová klasifikace 80,08 %.

Objektově orientovaná analýza obrazu se snaží napodobit vizuální interpretaci snímků člověkem. Člověk při pohledu na snímek nevyhodnocuje jednotlivé pixely, ale celé homogenní shluky. Na základě spektrálních, tvarových, kontextuálních a jiných informací rozpoznává jednotlivé objekty. Aby mohl počítač provádět takovéto vyhodnocení snímku, je nutné obraz nejprve rozdělit na tyto objekty (tzv. segmentace) a poté aplikovat klasifikační model. (Gisat, 200-?)

Právě segmentace je základním stavebním kamenem objektové klasifikace. Jednotlivé segmenty jsou generovány na základě jednoho nebo více kritérií homogenity. Oproti samostatným pixelům nesou i prostorovou informaci (Blaschke, 2010). Existuje několik přístupů k segmentaci obrazu (řízená, neřízená; top-down, bottom-up) a jsou založeny na různých přístupech definice homogenity (Gisat, 200-?). Segmentace top-down postupuje od větších objektů k menším. Na začátku je tedy celý obraz považován za jeden velký segment, který je dále dělen na menší celky. Na rozdíl od segmentace založené na principu bottom-up, kdy se postupuje od nejmenších objektů k větším. Na počátku procesu jsou za segmenty považovány jednotlivé pixely, které se postupně spojují ve větší celky. (Levin a Weiss, 2009)

Metoda objektové klasifikace má podle dostupné literatury široké spektrum využití. Využívá se pro detekci budov a klasifikaci zastavěných území (Myint et al., 2011; Cleve et al., 2008). Další velmi častý způsob použití je klasifikace vegetace (McMahan et al., 2003; Laliberte et al., 2007). V menší míře, ale důležité uplatnění má při různých přírodních událostech. Myint et al. (2008) identifikoval pomocí této metody tornádem poškozené oblasti. Jako vstup byl použit snímek Landsat TM s prostorovým rozlišením 28,5 m a sedmi pásmy. Objektovou klasifikaci zároveň srovnával s metodou řízené klasifikace maximum likelihood a metodou neřízené klasifikace ISODATA. Při použití pásem 3 (0,63-0,69 μm) a 4 (0,76-0,90 μm) dosáhla neřízená klasifikace celkové přesnosti 85 % a řízená klasifikace 87,5 %. Zatímco objektová klasifikace dosáhla použitím stejných pásem celkové přesnosti 98,33 %. Van de Sande et al. (2003) ji použil pro mapování rizika výskytu povodní v určitých oblastech a následné vyhodnocení škod.

2.1 Klasifikace vegetace

Vzhledem k velkému množství využití objektově-orientované klasifikace, záleží na výběru vhodné klasifikační metody. Při klasifikaci vegetace obecně platí, že pro heterogenní společenstva, kde je větší variabilita uvnitř pixelu, jsou vhodnější měkké a statisticky založené klasifikátory, jako je například fuzzy klasifikace. Oproti tomu u homogenních společenstev je vhodnější použít tvrdé klasifikátory, které dosahují dobrých výsledků. Měkké klasifikátory určují pravděpodobnost, s jakou patří objekt do každé z klasifikačních tříd, v podobě hodnoty z rozmezí 0 až 1. Naopak tvrdé klasifikátory (např. maximum likelihood, prahování) určují příslušnost daného objektu

do třídy buď jako hodnotu 0 (nepřísluší) nebo jako hodnotu 1 (přísluší). (Sha et al., 2008)

Fuzzy klasifikaci využil ve své práci McMahan et al. (2003) a zároveň tuto metodu porovnával s metodou řízené klasifikace maximum likelihood. Hlavním cílem bylo zmapování stepní vegetace na náhorní plošině Snake River v jihovýchodní části státu Idaho. Vegetace náhorní plošiny je tvořena především stepními ekosystémy, kde dominuje pelyněk a různé druhy trav. Kromě vegetace se zde vyskytuje holá půda a lávové proudy různého stáří. Jako vstup byl použit snímek Landsat 7 ETM+ ze 7. 8. 2002. Sběr terénních dat k vytvoření tréninkových ploch pro oba typy klasifikací proběhl v létě 2002. Následně byly stanoveny dvě varianty skupin tříd, do kterých byl snímek klasifikován. První varianta obsahovala třídy pelyněk a travní porosty. Druhá varianta třídy pelyněk, travní porosty a smíšenou kategorii. Řízená klasifikace metodou maximum likelihood dosáhla celkové přesnosti 33,7 % a 47,5 %. Oproti tomu fuzzy klasifikace dosáhla přesnosti 39,5 % a 50,5 %. Výsledky ukazují, že fuzzy klasifikace je vhodnější pro takto heterogenní a složité ekosystémy a vykazuje větší flexibilitu než řízená klasifikace. Ovšem výsledná klasifikační přesnost v této studii je omezena hrubým prostorovým rozlišením použitých družicových dat, která způsobují velkou heterogenitu tréninkových ploch. Větší homogenitu a zároveň lepší výsledky klasifikace by mělo přinést použití multispektrálních dat s vyšším prostorovým rozlišením.

Objektově orientovanou analýzu obrazu použil ve své práci Laliberte et al. (2007) pro odlišení zelené a stárnoucí vegetace v Novém Mexiku. Využil zde kombinaci metody rozhodovacího stromu a nejbližšího souseda. Zájmové území se nachází v nadmořské výšce okolo 1 200 m n. m. Celkové území se skládá ze snímků 50 parcel. Snímky byly pořízeny digitálním fotoaparátem s rozlišením 3264×2448 pixelů z výšky 2,8 m. Následná klasifikace proběhla v programu eCognition. Nejprve bylo nutné transformovat snímky z RGB prostoru do IHS (Intensity, Hue, Saturation), aby bylo možné lépe oddělit vegetaci. Poté byly na základě snímků stanoveny čtyři klasifikační kategorie (půda, stín, zelená a stárnoucí vegetace). Prvním krokem rozhodovacího stromu bylo oddělení stínu od ostatních složek obrazu pomocí pásma Intensity. Dále se pomocí pásem Hue a Saturation odfiltrovala půda od pásem vegetace. Následně se na klasifikaci kategorií vegetace použila metoda nejbližšího souseda. Klasifikace dosáhla průměrné přesnosti 92 %. Z výsledků také vyplývá, že použití maskování na

odfiltrování stínů a půdy od vegetace pomocí pásem IHS, se jeví jako vhodná metoda při takto složitých klasifikacích.

2.2 Klasifikace vegetace nad horní hranicí lesa

Klasifikací horských společenstev se ve své práci zabýval Král (2009). Cílem této studie bylo získat komplexní informace o vegetačním krytu v Národní přírodní rezervaci Praděd (CHKO Jeseníky). Především se zaměřil na přechodné zóny mezi subalpínskými lesy a alpínskou tundrou. Dalším cílem bylo také v těchto místech zmapovat výskyt cizorodé kleče a antropogenních útvarů. Jako vstupní data byla použita ortofotomapa s infračerveným pásmem z 21. 8. 2000 a prostorovým rozlišením 0,9 m. Hlavní použitou metodou byla řízená klasifikace s využitím tvrdého klasifikátoru maximum likelihood. Vzhledem k vysoké spektrální variabilitě jednotlivých klasifikovaných tříd a nízkému spektrálnímu rozlišení ortofot docházelo k nejasnému odlišení jednotlivých skupin. Z tohoto důvodu byla nutná i texturní analýza obrazu. Z okna o velikosti 7×7 pixelů se vypočítala směrodatná odchylka uvnitř okna pro všechna tři pásma (zelené, červené a blízké infračervené). Cílem této analýzy bylo především rozlišit plochy porostlé smrky a plochy bez smrků. Následně bylo ještě nutné provést ruční klasifikaci, protože například komunikace a stavby se těmito způsoby nedají oddělit od skal nebo suchých smrků. Touto metodou klasifikace se podařilo oddělit 7 tříd krajinného pokryvu – antropogenní plochy, pastviny a holé plochy, kleč, listnaté stromy, smrkové kultury, stojící suché smrky a úlomky a skalní výchozy. Klasifikace dosáhla celkové přesnosti 78 %.

Také Zagajewski et al. (2005) ve své práci klasifikoval horskou vegetaci subalpínského, alpínského a subniválního pásma. Zájmové území se nachází ve východní části Tatranského národního parku v Polsku. Vstupem byly hyperspektrální letecké snímky pořízené dvěma senzory. První senzor DAIS 7915 obsahuje 79 spektrálních pásem v rozmezí 400-2600 nm. Prostorové rozlišení závisí na výšce letu a pohybuje se od 3 do 20 m. Druhý senzor ROSIS zahrnuje spektrální oblast od 400 do 850 nm a obsahuje 115 spektrálních pásem. Po geometrické korekci bylo prostorové rozlišení snímků ze senzoru DAIS 3 m a ze senzoru ROSIS 1 m. Na těchto datech pak vyzkoušel metodu neřízené klasifikace, řízené klasifikace maximum likelihood a metodu neuronových sítí. Výsledky jednotlivých klasifikací byly porovnávány s botanickými mapami, které vznikly na základě terénního výzkumu, v měřítku

1 : 10 000. Neřízená klasifikace dopadla velmi špatně. Autor se nezmiňuje o přesnosti výsledků, pouze uvádí, že důvodem je vysoká spektrální variabilita uvnitř jednotlivých kategorií. Nicméně na základě této klasifikace a vizuální interpretaci snímků bylo stanoveno sedm klasifikačních kategorií pro řízenou klasifikaci – kosodřevina, lesy, louky, skály, jezera, stíny a turistické trasy. Trénovací plochy pro každou kategorii obsahovaly minimálně 50 pixelů. Řízená klasifikace metodou maximum likelihood byla provedena dvakrát na snímku ze senzoru DAIS. V prvním případě byla vstupem všechna pásma snímku a klasifikace dosáhla celkové přesnosti 78 %. Nejvyšší přesnosti bylo dosaženo v kategoriích jezera a louky (90-100 %), nejnižší pak v kategoriích skály a turistické trasy (kolem 40 %). Ve druhém případě byla klasifikace provedena s menším počtem pásem. V tomto případě bylo dosaženo nižší přesnosti 71 %. Oproti předchozím výsledkům měly nejnižší přesnost kategorie lesy a louky (20-56 %) a nejvyšší jezera a kosodřevina (83-100 %). Autor doporučuje pro lepší výsledky použít kromě spektrálních vlastností snímku např. textury. Toto umožňuje např. metoda umělých neuronových sítí, která nezávisí na statistických parametrech určité třídy, jako je tomu v případě klasifikátoru maximum likelihood. V článku byla metoda neuronových sítí (algoritmus zpětného šíření – *angl.* Back propagation) použita na snímek ze senzoru ROSIS pro klasifikaci kategorie kosodřeviny. Nejlepšího výsledku bylo dosaženo v kombinaci skrytých vrstev 3×3 a parametru *Threshold* 0,5. Chyba klasifikace byla v tomto případě nižší než 15 %. Autor předpokládá, že by tato metoda mohla dosahovat dobrých výsledků i v ostatních kategoriích.

Resler et al. (2004) použil ve své práci při klasifikaci alpínské vegetace metodu řízené klasifikace maximum likelihood a texturní analýzu obrazu. Zájmové území o rozloze 150 km^2 se nachází v národním parku Glacier ve státě Montana. Vstupními daty bylo černobílé ortofoto s prostorovým rozlišením 2 m. Snímek byl klasifikován do čtyř kategorií (kosodřevina, lesní porosty, alpínské louky a holá tundra). Hodnocení přesnosti proběhlo na základě mapy vytvořené z kombinace pozemních snímků a snímků pořízených helikoptérou. Celková přesnost klasifikace metodou maximum likelihood na černobílém ortofotu byla 81,33 %. Nejvyšší přesnosti bylo dosaženo v kategorii holé tundry (94,44 %), nejnižší pak v kategorii alpínské louky (69,23 %). Pro texturní analýzu obrazu bylo zvoleno 6 velikostí oken (5×5 , 7×7 , 9×9 , 11×11 , 13×13 a 15×15 pixelů). Z každého okna bylo vypočítáno pět texturních parametrů (např. směrodatná odchylka nebo variance). Nově vzniklá pásma byla přidána

k původnímu snímku a klasifikace pak byla provedena na třiceti snímcích se dvěma pásmy. Nejlepších výsledků klasifikací bylo dosaženo při použití vypočítané směrodatné odchylky a variance. Průměrná přesnost se pohybovala mezi 80 % a 100 %. Nejvyšší celkové přesnosti bylo dosaženo při výpočtu směrodatné odchylky v okně o velikosti 9×9 pixelů (83,44 %). Co se týče jednotlivých kategorií, tak např. v kategorii alpské louky se průměrná přesnost se zvětšujícím se oknem pro výpočet textur snižovala. Naopak v kategoriích kosodřevina a lesní porosty bylo lepších výsledků dosaženo s většími okny (11×11 , 13×13 a 15×15 pixelů) pro výpočet textur (80-90 %). Je to způsobeno tím, že lesní porosty mají nízkou druhovou heterogenitu a velký jehličnatý strom může zaplnit celý pixel, proto větší okno lépe odhalí strukturu v rámci plochy a klasifikace je přesnější.

Klasifikaci subalpínské vegetace provedla ve své práci také Müllerová (2005). Hlavními metodami byly řízená a neřízená klasifikace. Pro mapování a hodnocení změn subalpínské vegetace byly použity multispektrální letecké snímky (s červeným, zeleným, modrým a infračerveným pásmem) z let 1986, 1989 a 1997. Zájmové území o rozloze cca 6 km² se nachází v Krkonoších (1300-1400 m n. m.) v okolí Labské boudy. Toto území bylo vybráno s ohledem na dostupnost leteckých snímků a botanických map, které byly vytvořeny na základě terénního výzkumu. Cílem práce bylo zjistit, zda jsou tato data vhodná pro klasifikaci subalpínské vegetace a do jaké míry je možné odlišit jednotlivé typy vegetace. Dále jestli jsou výsledky této analýzy srovnatelné s výsledky získanými v terénu a do jaké míry je možné detekovat časové změny na vegetaci s využitím časové řady snímků. Nejprve bylo nutné převést analogové letecké snímky do digitální podoby. Jednotlivé kanály se naskenovaly z negativu, následně byly snímky vzájemně ztotožněny a nakonec georeferencovány pomocí ortofota. Prostorové rozlišení dat bylo 1 m. Klasifikace vegetace byla provedena na snímku z roku 1989. Na zvýraznění vegetace byly využity metody vyrovnání histogramu, PCA a NDVI. Hodnocení přesnosti bylo u obou metod provedeno deskriptivní a analytickou technikou, kterou popsal ve své práci Congalton (1991). Referenční plochy byly poté náhodně rozmístěny na snímku tak, aby se nepřekrývaly s trénovacími plochami.

U neřízené klasifikace byl použit klasifikátor ISODATA. Touto metodou se podařilo odlišit 6 tříd – (1) kosodřevina, (2) společenstva smilky tuhé, (3) vysoké trávy a bylinná společenstva (převažující bezkolenec modrý a třtina chloupkatá), (4) vegetace

podél silnic s vysokými trávami a bylinnými společenstvy, (5) silnice nebo společenstva smilky a (6) silnice nebo nízké trávy a byliny (metlice trsnatá). Některé důležité typy povrchu se od sebe nepodařilo odlišit jako silnice od společenstev smilky v kategorii 5. Celková přesnost klasifikace dosáhla hodnoty 63 %. V řízené klasifikaci byl použit klasifikátor maximum likelihood a bylo stanoveno 7 klasifikačních tříd – (1) kosodřevina, (2) společenstva smilky, (3) vysoké trávy a bylinná společenstva, (4) vegetace podél silnic, (5) silnice, (6) vodní plochy, (7) zamokřená území (rašeliniště). Tato klasifikace dosáhla celkové přesnosti 79 %. Nejvyšší přesnost byla dosažena v kategoriích 1 (zpracovatelská přesnost 88,4 %, uživatelská přesnost 86,6 %) a 2 (zpracovatelská přesnost 81,2 % a uživatelská přesnost 84,8 %).

Ve srovnání s botanickými mapami, se přesnost jednotlivých tříd pohybovala od 24 % do 75 %. Nejvyšší přesnosti bylo opět dosaženo v kategoriích 1 a 2, které jsou ze snímků velmi dobře patrné. Celková přesnost neřízené klasifikace byla 59 % a řízené 55 %. Pro porovnání změn vegetace v čase byla použita pouze třída kosodřeviny, která dosáhla nejvyšší přesnosti. Z výsledků vyplývá, že za 11 let (1986 – 1997) její rozloha rostla průměrně 2,8 ha za rok. Multispektrální letecká data se ukázala jako vhodná pro klasifikaci subalpínské vegetace, především díky rychlosti a menší pracovní náročnosti na zpracování.

2.3 Objektová klasifikace

Pro objektovou klasifikaci byl použit software ENVI 5.1 doplněný o modul *Feature Extraction*. Licenci k softwaru poskytla firma ARCDATA PRAHA s.r.o. se svolením společnosti Exelis Visual Information Solution. Program nabízí v modulu *Feature extraction* dva přístupy k objektové klasifikaci – *Example-Based* a *Rule-Based*.

2.3.1 Segmentační algoritmy v ENVI

Prvním a časově nejnáročnějším krokem jakékoli objektové klasifikace je segmentace. V nabídce ENVI jsou dva segmentační algoritmy – *Edge* a *Intensity*. Oba algoritmy fungují na principu bottom-up, čili jednotlivé pixely s podobnými spektrálními vlastnostmi jsou shlukovány do větších regionů (segmentů). Každý segment pak obsahuje průměrnou spektrální hodnotu všech pixelů, které do něho spadají. Pro lepší

výsledky segmentace se doporučuje použít kombinaci dvou až čtyř spektrálních pásem (Exelis VIS, 2014b). Cílem je tedy rozdělit snímek na přibližně homogenní objekty.

Algoritmus *Edge* rozděluje snímek na základě Sobelovy metody detekce hran. Objekty zájmu mají často jasné hranice, které jsou reprezentovány velkou změnou intenzity, zatímco uvnitř objektů je intenzita rozdělena relativně rovnoměrně. Poté je potřeba nastavit *Scale Level*, který nabývá hodnot 0-100. Čím vyšší je hodnota, tím více jsou identifikovány pouze objekty s výraznějšími hranami (např. střechy, silnice apod.) – tj. větší objekty. Pro spojení malých segmentů do větších je zde parametr *Merge*. Ten nabízí dva spojovací algoritmy – *Full Lambda Schedule* a *Fast Lambda*. Zároveň se u každého algoritmu nastavuje *Merge Level* v rozmezí hodnot 0-100. Algoritmus *Full Lambda Schedule* spojuje sousedící segmenty na základě kombinace spektrální a prostorové informace, zatímco algoritmus *Fast Lambda* na základě Euklidovské vzdálenosti jejich barevných odstínů a délce jejich hranice (Exelis VIS, 2014b). Algoritmy jsou dány následujícími vztahy:

Full Lambda Schedule:

$$t_{i,j} = \frac{\frac{|O_i| \cdot |O_j|}{|O_i| + |O_j|} \cdot \|u_i - u_j\|^2}{\text{length}(\partial(O_i, O_j))}$$

$|O_i|, |O_j|$ - plocha segmentu i, j
 $\|u_i - u_j\|$ - Euklidovská vzdálenost mezi průměrnými spektrálními hodnotami segmentů i a j
 $\text{length}(\partial(O_i, O_j))$ – délka hranice regionů O_i a O_j

Fast Lambda:

$$\text{Lambda} = \left[\frac{N_1 N_2}{N_1 + N_2} \right] \frac{E}{L}$$

N_1, N_2 – počet pixelů v segmentu 1 a 2
 E – Euklidovská vzdálenost mezi barevnými odstíny segmentu 1 a 2
 $L = \text{length}(\partial(O_i, O_j))$ – délka hranice segmentu 1, 2


Druhý segmentační algoritmus *Intensity* je vhodný pro snímky s rostoucí intenzitou barvy bez jasně definovaných hranic, jako např. DEM nebo snímek elektromagnetického pole. V tomto případě se *Merge Level* nenastavuje.

Pokud se bude při klasifikaci využívat texturních parametrů snímku, je potřeba nastavit *Texture Kernel Size*, což je velikost (v pixelech) pohybujícího se okna, ve kterém se ze všech pixelů, které do něho spadají, vypočítávají texturní parametry (Exelis VIS, 2014b). Nevýhodou procesů segmentace v ENVI je, že segmentace musí


proběhnout vždy při každém spuštění, čili nelze použít jednou rozsegmentovaný snímek do dalších klasifikací.

2.3.2 Klasifikace *Example-based*

Klasifikací *Example-based* jsou jednotlivé segmenty zařazovány do předem stanovených kategorií pomocí trénovacích ploch (segmentů), vybraných atributů a klasifikačního algoritmu. Pro stanovení trénovacích ploch existují dva způsoby. Uživatel může přímo na snímku označit jednotlivé segmenty jako trénovací nebo nahrát trénovací plochy ve formátu *.shp*. V tomto případě lze ještě zvolit způsob označení segmentů jako trénovacích. Buďto budou označeny všechny, které se protnou s hranicí trénovací plochy (Obr. 1), nebo to bude pouze ten, do kterého spadá těžiště trénovací plochy (Obr. 2).



Obr. 1: Označení všech segmentů, které protne trénovací plocha



Obr. 2: Označení segmentu, do kterého spadne těžiště trénovací plochy

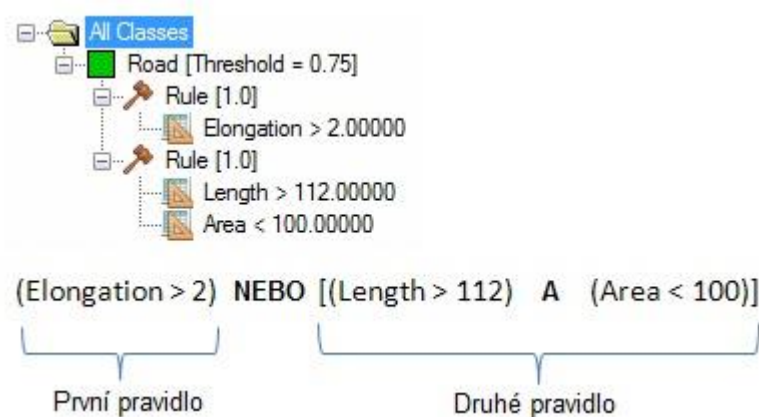
Po nahrání trénovacích ploch uživatel vybere atributy, na základě kterých bude snímek klasifikován do stanovených kategorií. K dispozici jsou atributy spektrální (např. *Spectral Mean*, *Spectral Min*), texturní (např. *Texture Mean*, *Texture Range*) a prostorové (např. plocha, délka, kompaktnost).

Posledním krokem je pak vybrání klasifikačního algoritmu. V softwaru ENVI jsou v nabídce tři – KNN (*K Nearest Neighbor*), PCA (*Principal Components Analysis*) a SVM (*Support Vector Machine*). Po několika zkušebních klasifikacích byl pro účely klasifikace v bakalářské práci vybrán algoritmus SVM, který bude blíže popsán

v kapitole 2.4. Poslední parametr, který může být nastaven, je *Threshold*. Udává se v procentech, a pokud je shoda zařazovaného segmentu s trénovacími segmenty nižší než nastavená hodnota, tak tento segment nebude zařazen do žádné kategorie (Exelis VIS, 2014b).

2.3.3 Klasifikace *Rule-based*

Každá třída, do které jsou jednotlivé segmenty zařazovány, obsahuje jedno nebo více klasifikačních pravidel vytvořených uživatelem. Každé pravidlo zahrnuje jeden nebo několik atributů jako např. průměrná odrazivost v daném pásmu, plocha, délka, textura (Exelis VIS, 2014b). Uživatel u každého atributu stanoví rozmezí hodnot, které platí pro tu danou kategorii. Na obrázku 3 je zobrazen příklad klasifikačních pravidel pro třídu *Road* a logika mezi nimi.



Obr. 3: Klasifikační pravidla (Exelis VIS, 2014b, upravené autorkou)

2.4 Support Vector Machine (SVM)

Algoritmus SVM je statistická učící se metoda založená na principu tzv. strukturální minimalizace rizika (Vapnik's Structural Risk Minimization principle) (Vapnik, 1998). Jedná se o metodu řízené klasifikace, která je v poslední době velmi často využívána, jelikož podle srovnávacích studií dosahuje lepších výsledků než jiné metody jako např. neuronové sítě, rozhodovací stromy nebo klasifikátor maximální věrohodnosti (Foody a Mathur, 2004; Huang et al., 2002).

Obecně lze říci, že algoritmus SVM převádí úlohu klasifikace z nelineárně separovatelných tříd na úlohu klasifikace do tříd lineárně separovatelných (Pejčoch,

2011). Tímto prostorem transformovaných atributů je následně proložena tzv. optimální dělící nadrovina, jejíž vzdálenost od trénovacích tříd je co největší (Zhu a Blumberg, 2002). Trénovací data nelineárně separovatelných tříd jsou implicitně převedena kernelovou funkcí do vícerozměrného prostoru, ve kterém je možné lépe proložit dělící nadrovinu. Body, které jsou nejbližší této nadrovině se nazývají pomocné vektory (*angl.* support vectors). Pro stanovení optimální dělící nadroviny jsou potřeba jen ty s nenulovou váhou (van der Linden et al., 2014).

V DPZ je s ohledem na přiměřenou dobu zpracování nejvíce používanou kernelovou funkcí *Radial Basis*. Zde je potřeba nastavit parametr g a C . Parametr g definuje šířku kernelové funkce. Regularizační parametr C je kompromisem mezi maximalizací okrajů vektorů tréninkových dat a hraniční linií a zároveň penalizuje chyby, čili přímo ovlivňuje váhu jednotlivých vektorů. (van der Linden et al., 2014)

3 Charakteristika zájmového území

Krkonoše jsou nejvyšším pohořím střední Evropy severně od Alp. Jejich svahy se zvedají nad alpskou hranici lesa a tím vytvářejí přirozený val na okraji rozsáhlých nížin Německa a Polska. Celková délka Krkonoš je přibližně 35 km a hlavní hřebety a údolí jsou uspořádány ve směru severozápad-jihovýchod. I přes malou rozlohu a nízkou nadmořskou výšku se zde nachází velice rozmanitá flóra a fauna. Krkonoše se tak řadí mezi významná centra biodiverzity střední Evropy. V roce 1963 zde byl zřízen první národní park v České republice KRNAP. (KRNAP, 200-?)

Zájmové území s rozlohou okolo 12 km² se nachází v západní části Krkonoš v okolí Labské boudy. Zahrnuje nadmořské výšky od přibližně 1 250 m n. m. až po 1 500 m n. m. Přehledová mapka zájmového území je v příloze 1.

3.1 Arkto-alpínská tundra Krkonoš

Abychom mohli lépe pochopit výskyt tundry v Krkonoších, je třeba si uvědomit jejich polohu na rozhraní horských masivů střední, západní a severní Evropy. Ze všech vyšších hercynských středohoří (Vysoké Sudety, Harz, Schwarzwald, Vogézy a Centrální masiv), krkonošské hřebeny nejvíce převyšují alpskou hranici lesa, která se v Krkonoších pohybuje kolem 1 300 m n. m. Zároveň jsou Krkonoše významným spojovacím článkem se severskou tundrou i přes velké rozlohy severoněmeckých a polských nížin. Během pleistocenního zalednění došlo k rozšíření skandinávského ledovce směrem na jih a při jeho okrajích pronikala severská tundra do střední Evropy. Naproti tomu z Alp sestupovala alpská tundra a horské trávníky. Po oteplení v holocénu vznikla z nikdy nezaledněných nejvyšších poloh Krkonoš bezlesá horská krajina uprostřed střední Evropy. Stabilizovala se zde početná populace reliktních severských a alpských druhů. Díky dlouhodobé izolovanosti nejvyšších poloh Krkonoš od ostatních vysokých pohoří zde zároveň došlo ke specifickým mikroevolučním procesům a vzniku nových endemických druhů a poddruhů rostlin a živočichů. (Štursa, 2013)

Soukupová et al. (1995) ve své studii poprvé zavedli pojem arkto-alpínská tundra, který nejlépe vystihuje procesy, které se zde během pleistocénu a na začátku holocénu odehrávaly a jsou nadále udržovány současným podnebím. Průměrná roční teplota se

pohybuje od 0 °C do +1 °C, je tu tedy velmi krátké období průměrných denních teplot nad hodnotu 0 °C. Průměrný roční úhrn srážek je 1 400 mm a sněhová pokrývka je zde 180 dní. Dochází také k intenzivní eolické činnosti v nejvyšších hřbetových partiích. Náhorní plošiny jsou tvořeny krystalickými metamorfovanými horninami, které jsou pokryté chudými, kyselými půdami a polygonálními půdami.

Na relativně malé ploše 47 km², což je pouze 7,4 % z celkové rozlohy Krkonoš (32 km² na české a 15 km² na polské straně hor), se zde nachází bohatý soubor kryogenních tvarů a široká mozaika vysokohorských a severských ekosystémů (Štursa, 2013). Pro detailnější a přehlednější členění arкто-alpínské tundry Soukupová et al. (1995) charakterizovali zónu kryo-eolickou (nejvyšší vrcholy a hřbety s kamennými moři a alpínskými vyfoukávanými trávničky), kryo-vegetační (třetihorní vrcholové plochy s vyrovnaným terénem, severskou vegetací, subarktickými mokřady a vysokými srážkovými úhrny) a niveo-glaciální (ledovcové kary a nivační deprese na závětrných svazích, travinná, vysokostébelná a křovinná vegetace).

Jak již bylo výše zmíněno, zdejší flóra je velice pestrá a bohatá. Mezi jeden z nejrozšířenějších typů vegetace patří klečové porosty a smilkové trávničky. Dominujícími druhy jsou borovice horská (kleč, kosodřevina), která je původní krkonošskou dřevinou, a smilka tuhá. Smilkové louky, obrazně nazývány jako „hercynská poušť“, jsou převážně přirozeného původu, ale místy druhotně pokrývají plochy po vysekané nebo vypálené kleči. Dalším velmi významným typem jsou severská rašeliniště, která jsou svým uspořádáním a přírodními poměry velmi podobná rašeliništím severní Evropy. Nachází se zde mnoho glaciálních reliktních oSTRUŽINÍK moruška, všivec krkonošský a rašeliník Lindbergův. Na nejvyšších a vzájemně izolovaných vrcholech Krkonoš (Vysoké Kolo a Kotel v západní části) nalezneme mozaiku kamenitých sutí a řídkou vegetaci severských a alpínských mechorostů, lišejníků a travin. Vyskytuje se tu velké množství jestřábníků, z nichž některé druhy jsou krkonošskými endemity. Na závětrných svazích ledovcových karů se nachází květnatá tundra (tzv. krkonošská botanická zahrádka). Mezi význačné druhy rostlin patří například endemický jeřáb sudetský, rybíz skalní nebo sasanka narcisokvětá. (KRNAP, 200-?)

4 Data a Metodika

Tato kapitola začíná podrobným popisem legendy, podle které byl snímek klasifikován. Správné definování legendy je totiž klíčovým krokem pro celou klasifikaci. Dále jsou podrobně popsána veškerá data, včetně terénních. Metodika se pak zabývá tvorbou masky vegetace, segmentací a dvěma přístupy k objektově-orientované klasifikaci.

4.1 Legenda vegetace nad horní hranicí lesa

Použitá legenda byla vytvořena ve spolupráci s botanikem Krkonošského Národního Parku RNDr. Stanislavem Březinou, Ph.D. a zahrnuje celkem 10 kategorií a 7 podkategorií. Zároveň jsou na konci kapitoly zobrazeny ukázky spekter jednotlivých kategorií nasbíraných v terénu. Spektra byla pořízena spektrometrem ASD FieldSpec 4 Wide-Res v kombinaci s kontaktní sondou.

1. Kosodřevina

Kosodřevina roste na horských svazích, plošinách a hřebenech od 1 200 do 1 450 m n. m. Půdy jsou většinou kamenité, silně kyselé horské podzoly nebo mělké rankery s vyvinutou vrstvou surového humusu. Převažujícím druhem je borovice kleč (*Pinus mugo*). V keřovém patře, které má výšku 0,5-2 m, se spolu s klečí nejčastěji vyskytuje smrk ztepilý (*Picea abies*) a jeřáb ptačí olýsalý (*Sorbus aucuparia* subsp. *glabrata*). Bylinné patro je druhově chudé a vykytují se v něm nenáročné acidofilní rostliny např. metlička křivolaká (*Avenella flexuosa*), smilka tuhá (*Nardus stricta*) nebo třtina chloupkatá (*Calamagrostis villosa*). (Kočí, 2001b)



Obr. 4: Kosodřevina (foto: Lucie Červená)

2. Mokřad

2a. Rašeliniště

Vysokohorská rašeliniště jsou sycená převážně srážkovou vodou a někdy současně obohacovaná minerálně chudou podzemní vodou. Prostředí je silně kyselé. Pokud se zde vyskytuje kleč, dosahuje výšky jen kolem 0,5 m. Dominantními rostlinnými druhy jsou rašelínky, např. vínově červený rašelíník prostřední (*Sphagnum magellanicum*), rašelíník hnědý (*S. fuscum*) nebo rašelíník bradavčitý (*S. papillosum*). V bylinném patře je hojně zastoupený suchopýr pochvatý (*Eriophorum vaginatum*). (Hájek a Rybníček, 2001)



Obr. 5: Rašeliniště (foto: Lucie Červená)

2b. Mokřad – ostatní

Do této kategorie jsou zařazena prameniště rašeliniště, ve kterých se často vyskytují odumřelé kmeny kleče a na okrajích mohou být zrašelinělé smilkové porosty. Dále to jsou nivy potoků nebo nevápnitá mechová slatiniště. Hojně zastoupenými bylinami jsou např. suchopýr úzkolistý a široolistý (*Eriophorum angustifolium*, *E. latifolium*), suchopýrek alpský (*Trichophorum alpinum*) nebo ostřice obecná (*Carex nigra*). Z mechorostů zde nalezneme např. klamonožku bahenní (*Aulacomnium palustre*) nebo vlasolstec vlhkomilný (*Homalothecium nitens*). (Hájek a Rybníček, 2001)



Obr. 6: Mokřad – ostatní (foto: Lucie Červená)

3. Vodní plochy

Jedná se převážně o jezírka v rašeliništích (tzv. šlenky) či mokřadech o velikosti cca 100-400 m². Jsou různého tvaru, od přibližně kruhových až oválných po výrazně protáhlá jezírka po vrstevnici (Hájek a Rybníček, 2001).



Obr. 7: Vodní plocha (foto: Lucie Červená)

4. Alpínská vřesoviště

Vyskytují se na vyfoukávaných místech nad horní hranicí lesa, především na mělkých substrátech nebo na vrcholových skalách. Jedná se o porosty drobných keříčků, kde převažujícím druhem je vřes obecný (*Calluna vulgaris*). Místy se vyskytují i brusnicovité druhy (*Vaccinium myrtillus*, *V. vitis-idaea*). Často jsou zde zastoupeny jestřábníky z okruhu *Hieracium alpinum*, lišejníky a mechy rodů *Cetraria*, *Cladonia* nebo *Polytrichum*. (Krahulec a Kočí, 2001)



Obr. 8: Alpínská vřesoviště (foto: Lucie Červená)

5. Subalpínská brusnicová vegetace

Porosty brusnic rostou na závětrných i návětrných svazích v blízkosti horní hranice lesa, dále na konvexním reliéfu v závětrném prostoru karů a na vrcholových plošinách společně s kosodřevinou. V zimě je chráněno před mrazem vysoká sněhová pokrývka. Půdy jsou kamenité, mělké a vysychavé, na jejichž povrchu se hromadí surový humus. Jedná se o druhově chudé porosty nízkých keříčků tvořené především borůvkou (*Vaccinium myrtillus*) a brusinkou (*V. vitis-idaea*). Často mezi nimi najdeme juvenilní dřeviny např. smrk ztepilý (*Picea abies*) a borovice kleč (*Pinus mugo*), které kvůli extrémnímu klimatu nedorůstají vyšší výšky. Bylinné patro je vedle borůvky a brusinky tvořeno převážně trávami jako třtina chloupkatá (*Calamagrostis villosa*) a metlička křivolaká (*Avenella flexuosa*). Obvykle je vyvinuto i mechové patro. (Krahulec a Kočí, 2001)



Obr. 9: Subalpínská brusnicová vegetace (foto: Lucie Červená)

6. Alpínské trávníky zapojené

Jedná se o nízké trávníky o výšce do 25 cm. Vyskytují se na plochých hřebenech, vrcholových plošinách (s výjimkou deflačních) a mírných svazích nad horní hranicí lesa. Po celou zimu jsou chráněny vyšší vrstvou sněhové pokrývky. Půdy jsou převážně kamenité, chudé na živiny, ale dobře vyvinuté a hluboké. Mechové patro většinou chybí nebo je jen slabě vyvinuto. (Kočí, 2001a)

6a. Smilka

Smilka tuhá (*Nardus stricta*) je vytrvalá trsnatá tráva dorůstající výšky 5-30 cm. Stébla jsou tuhá a tvrdá, listy jsou šedozelené, tenké a drsné. Vyskytuje se od nížin až po alpínské pásmo hor, na horských loukách a pastvinách, kolem cest, na okrajích rašelinišť a na vřesovištích. (Soják, 1983)



Obr. 10: *Smilka* (foto: Lucie Červená)

6b. Metlička

Metlička křivolaká (*Avenella flexuosa*) je vytrvalá, řídce trsnatá tráva, stébla jsou vysoká 30-70 cm. Nalezneme ji na pasekách nebo vřesovištích, ve světlých jehličnatých lesích často tvoří souvislé porosty (Kubát et al., 2002). Jedná se o indikační druh kyselých půd se zhoršeným rozkladem humusu (Dvorský, 2009).



Obr. 11: *Metlička* (foto: Lucie Červená)

6c. Druhově bohaté porosty s velkým zastoupením dvouděložných

V této skupině je zastoupena např. ostřice Bigelowova (*Carex bigelowii*), podbělice alpská (*Homogyne alpina*), kostřava nízká (*Festuca supina*) a místy se může vyskytovat i bezkolenec modrý (*Molinia caerulea*) nebo metlice trsnatá (*Deschampsia cespitosa*) (Kočí, 2001a).



Obr. 12: Druhově bohaté porosty s velkým zastoupením dvouděložných
(foto: Lucie Červená)

7. Subalpínské vysokostébelné trávníky

Nalezneme je nejčastěji v karech na závětrných svazích jižní až východní orientace. Půdy jsou většinou suché, hluboké a hlinité, s různým obsahem skeletu. Důležitým faktorem je sníh, který chrání vegetaci před mrazem a působí i mechanickým tlakem. Vysokostébelné trávníky jsou nejvíce ohroženy vysazováním kosodřeviny, vysokými stavy jelení a kamzičí zvěře a expanzí trav metličky křivolaké a třtiny chloupkaté na úkor ostatních druhů. (Kočí, 2001c)

7a. Třtina

Druhově bohaté porosty třtiny rákosovité (*Calamagrostis arundinacea*) se maloplošně vyskytují na suchých a slunných místech v karech. Nejrozšířenější jsou porosty třtiny chloupkaté (*C. villosa*), které jsou většinou druhově velmi chudé (Kočí, 2001c). Jedná

se o vytrvalou, 60-150 cm vysokou travu s plazivým, dlouze výběžkatým oddenkem (Randuška et al., 1983).



Obr. 13: *Třtina* (foto: Lucie Červená)

7b. Bezkolenec

Bezkolenec modrý (*Molinia caerulea*) je mohutná trsnatá tráva dorůstající výšky až 120 cm (Kubát et al., 2002). Druhově chudé porosty bezkolence nalezneme na vlhčích místech pod hranami karů, kde delší dobu leží sníh (Kočí, 2001c).



Obr. 14: *Bezkoleneček* (foto: Lucie Červená)

7c. Metlice

Metlice trsnatá (*Deschampsia cespitosa*) je vytrvalá, sytě zelená a hustě trsnatá tráva dorůstající výšky 30-150 cm (Randuška et al., 1983). Druhově chudé porosty s dominantní metlicí se lokálně vyskytují na hřebenech a náhorních plošinách, v mělkých terénních sníženinách a ve žlebech na mírných svazích (Kocí, 2001c).



Obr. 15: *Metlice* (foto: Lucie Červená)

8. Subalpínské vysokobylinné trávníky

Jedná se o travinobylinné porosty, jejichž typický vzhled utvářejí statné druhy širokolistých bylin, např. havez česnáčková (*Adenostyles alliariae*), kýchavice bílá Lobelova (*Veratrum album* subsp. *lobelianum*) nebo devětsil bílý (*Petasites albus*). Dorůstají výšky 50-100 cm. Nalezneme je na chráněných místech nad horní hranicí lesa, v okolí pramenišť a potoků a v karech. Půdy jsou vlhčí, hluboké a humózní. (Kočí, 2001c)






Obr. 16: Subalpínské vysokobylinné trávníky (foto: Lucie Červená)

9. Smrk

Smrk ztepilý (*Picea abies*) se v těchto nadmořských výškách vyskytuje pouze v blízkosti horní hranice lesa. Kvůli silnému větru dorůstá pouze malé výšky.

Původně byla v legendě i kategorie vyfoukávaných alpínských trávníků, ale jelikož se v terénu nepodařilo nalézt dostatečně velkou a kompaktní plochu, byla tato kategorie odstraněna.



Obr. 17: Ukázky spekter jednotlivých kategorií naměřených v terénu spektrometrem ASD FieldSpec 4 Wide-Res a kontaktní sondou

4.2 Použitá data

Pro účely bakalářské práce byly použity tři hlavní datové zdroje: ortofota obsahující infračervené pásmo, digitální model terénu s digitálním modelem povrchu a GPS data získaná v terénu.

4.2.1 Data z leteckého optického skeneru

Data z leteckého optického skeneru byla pořízena v létě roku 2012. Data se skládají ze dvou sad ortofot po třech pásmech. Jedna sada obsahuje pásma viditelného spektra (červené, zelené a modré) a druhá blízké infračervené, červené a zelené pásmo. Radiometrické rozlišení dat je 8-bit. Velikost snímků je $2,5 \times 2$ km a jejich prostorové rozlišení 12,5 cm. Pro pokrytí celého zájmového území krkonošské tundry bylo potřeba třináct snímků.

4.2.2 DEM, DSM

V práci byl použit také digitální model terénu (*angl.* Digital Elevation Model) a digitální model povrchu (*angl.* Digital Surface Model). Digitální model terénu udává pouze nadmořskou výšku holého povrchu. Digitální model povrchu pak obsahuje kromě nadmořské výšky povrchu i výšku vegetace nebo budov. Oba modely vznikly zpracováním laserových dat pořízených na území KRNAP spolu s ortofoty v roce 2012. Pro pokrytí zájmového území bylo potřeba 36 snímků o velikosti 1×1 km s prostorovým rozlišením 1 m. Modely byly využity ke zjištění výšky vegetačního pokryvu (odečtením DEM a DSM) a zjištěná výška vegetace byla následně použita při klasifikaci smrku a kosodřeviny. Ukázka jednotlivých modelů je na obrázku 18.



Obr. 18: Ukázka jednotlivých modelů
(vlevo DEM, uprostřed DSM, vpravo rozdíl DEM a DSM)

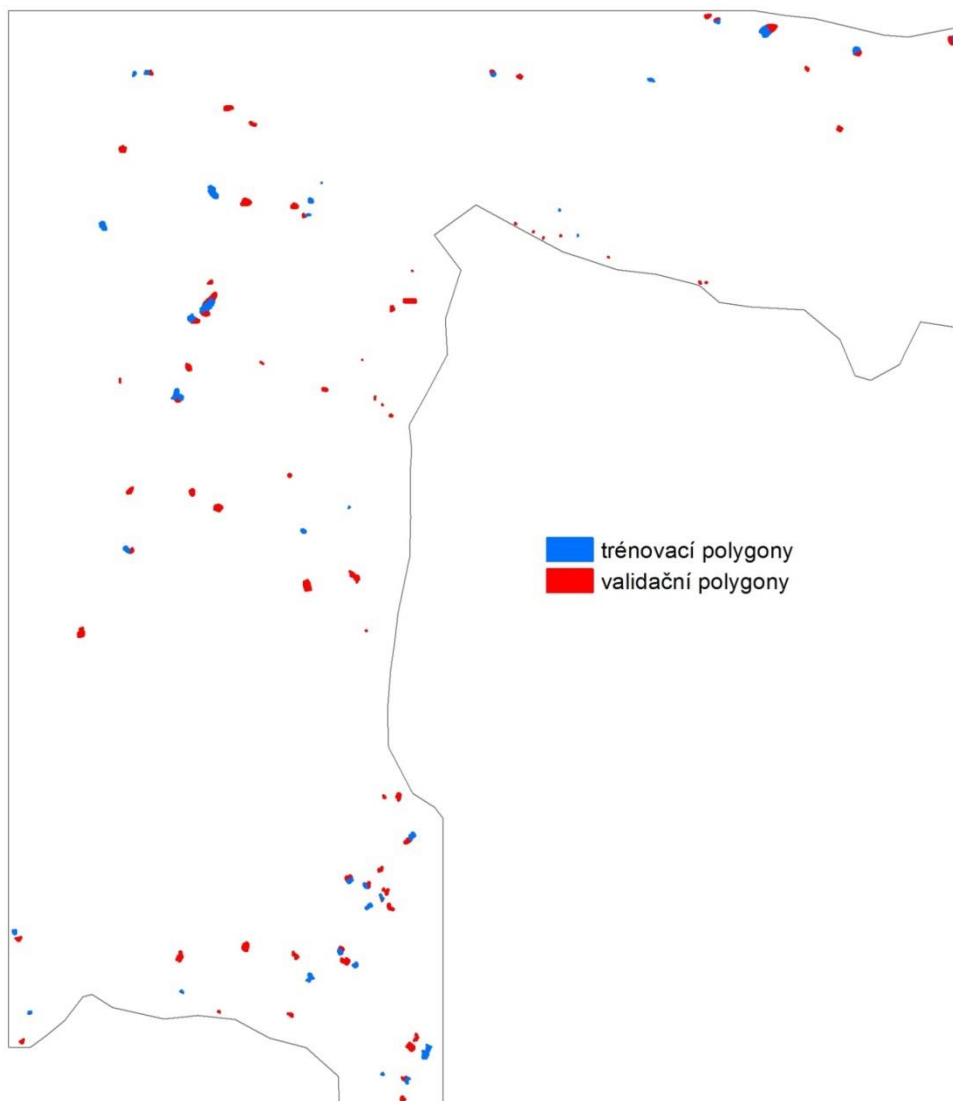
4.2.3 Terénní data

V terénu bylo nasbíráno 59 polygonů odpovídajících jednotlivým kategoriím legendy. Sběr dat proběhl v období 23. – 25. června 2014 za účasti botanika Krkonošského národního parku RNDr. Stanislava Březiny, Ph.D. a botanika Mgr. Jana Šturmy. Od pořízení obrazových tak sice uplynuly dva roky, ale v oblasti arкто-alpínské vegetace Krkonoš se předpokládá, že nedochází k příliš rychlým a rozsáhlým změnám ve výskytu jednotlivých druhů vegetace.

Polygony byly nasbírány pomocí přístroje GPS Trimble Geoexplorer 3000 Geo XT a následně botanikem zařazeny do jednotlivých kategorií legendy. V softwaru ArcGIS 10.2 byla opravena jejich geometrie, pokud např. nebyl polygon správně zakončený. Následně byly ještě polygony doupraveny nad ortofoty tak, aby ve výsledném polygonu, který bude použit jako trénovací či validační plocha, nebyly obsaženy stíny od stromů či staveb příp. jiné nepřesnosti, které by mohly nepříznivě ovlivnit výsledky klasifikací. Na základě ortofot byly také dodatečně vytvořeny polygony kategorií kosodřevina, smrk a vodní plochy, které jsou vizuální interpretací jednoznačně identifikovatelné a tak nemusely být sbírány v terénu. Poté byly všechny polygony rozděleny na trénovací a validační (Obr. 19) tak, aby validačních bylo nejlépe dvakrát více než trénovacích. V tabulce 1 jsou vidět jejich rozlohy a poměry.

Tab. 1: Rozlohy a poměry trénovacích a validačních polygonů

Kategorie	Trénovací polygony [m ²]	Validační polygony [m ²]	Trénovací/Validační
1	932,92	1649,33	0,57
2a	767,05	1010,06	0,76
2b	96,31	129,67	0,74
3	258,24	506,68	0,51
4	404,24	679,70	0,59
5	281,76	411,88	0,68
6a	564,37	874,95	0,65
6b	123,14	165,74	0,74
6c	244,98	315,72	0,78
7a	126,67	184,17	0,69
7b	206,24	468,11	0,44
7c	205,86	367,85	0,56
8	293,97	424,60	0,69
9	24,19	44,53	0,54



Obr. 19: Rozdělení polygonů na trénovací a validační

4.3 Předzpracování dat

Nejprve bylo nutné spojit ortofota z každé sady do jednoho rastrového datasetu, což bylo provedeno v softwaru ArcGIS 10.2 pomocí funkce *Mosaic To New Raster*. Stejným způsobem byly spojeny i rastry reprezentující výšku pokryvu – tj. rozdíly mezi DEM a DSM.

Hranice tundry byla vytvořena botanikem z Krkonošského národního parku RNDr. Stanislavem Březinou, Ph.D. a dodána ve formátu *.shp*. Dle této hranice byly pak oříznuty veškeré rastry funkcí *Extract by Mask*. Po vytvoření kompozice ze všech čtyř pásem funkcí *Layer stacking* v softwaru ENVI 5.1 a po výpočtu pyramid měl daný

snímek velikost 16 GB. Analýza takto velkého snímku nebyla dostupnou výpočetní technikou a času potřebného na výpočet možná. Proto byla vybrána pouze část území (Obr. 20), která obsahovala všechny kategorie legendy.



Obr. 20: Výřez zájmového území

4.3.1 Vegetační indexy

Vegetační indexy (někdy také nazývány jako spektrální) zahrnují jednoduché aritmetické operace s dvěma či více pásmy multispektrálního obrazu. Velkou část tvoří především jejich podíly. Výsledkem podílu dvou pásem stejného území je obraz, který přesněji vystihuje spektrální charakteristiky objektů. Cílem vegetačních indexů je zvýraznění vegetační složky v obraze, avšak některé z nich zobrazují i vlastnosti půdního substrátu. Vegetační indexy vycházejí z typického spektrálního chování vegetace. Zdravá a nepoškozená vegetace odráží v blízké infračervené části spektra ($0,7-1,1\ \mu\text{m}$) 40-50 % dopadajícího záření, zatímco ve viditelné oblasti ($0,4-0,7\ \mu\text{m}$) odráží pouze 10-20 % v důsledku pohlcování záření chlorofylem a dalšími pigmenty. (Dobrovolný, 1998)

Vegetačních indexů a algoritmů pro jejich výpočet existuje celá řada. Na základě způsobu výpočtu je můžeme rozdělit do tří skupin: diferenční, poměrové a ortogonální. V práci byly použity následující vegetační indexy: jednoduchý poměr blízkého infračerveného a červeného pásma SR (někdy je uváděn jako RVI – Ratio Vegetation

Index), NDVI, GRDI a poměr zeleného a blízkého infračerveného pásma. Seznam použitých indexů a poměrů a jejich výpočet je v tabulce 2.

Tab. 2: Seznam použitých indexů

Indexy/poměry	Algoritmus	Reference
SR: Simple ratio	$SR = NIR/R$	(Jordan, 1969)
NDVI: Normalized Difference Vegetation Index	$NDVI = (NIR - R)/(NIR + R)$	(Dobrovolný, 1998)
GRDI: Green Red Difference Index	$GRDI = (G - R)/(G + R)$	(Gitelson et al., 2002)
G/NIR	G/NIR	

4.3.2 Maska vegetace nad horní hranicí lesa

Jelikož zájmové území obsahuje i jiné prvky krajinného pokryvu než vegetaci (cesty, střechy, atd.) a zároveň se ve snímku nacházejí nežádoucí stíny (od stromů, budov apod.), bylo potřeba vytvořit masku, pod kterou se bude klasifikovat vegetace tundry. Na základě vizuální interpretace byly stanoveny 3 klasifikační kategorie: střechy a holá půda (kamenná moře, cesty, atd.), stíny, vodní plochy (kategorie legendy číslo 3). Samotná maska byla vytvořena pomocí objektové klasifikace *Rule-based* v softwaru ENVI 5.1.

Jak již bylo zmíněno výše, prvním a nejdůležitějším krokem celého procesu je segmentace. V tomto případě proběhla segmentace na základě kombinace červeného, zeleného a blízkého infračerveného pásma. V nastavení hodnot segmentace byl zvolen algoritmus *Edge*. Pomocí náhledu byla zvolena jako nejvhodnější kombinace hodnot pro *Scale level* 50 a pro *Merge level* 90. *Merge level* byl vypočítán algoritmem *Full Lambda Schedule* (teorie viz kapitola 2.3.1). Pro samotnou klasifikaci byla zvolena pásma NDVI, G/NIR a blízké infračervené. V tabulce 3 je seznam použitých pravidel, podle kterých klasifikace proběhla. Na obrázku 21 je pak zobrazena výsledná maska vegetace nad horní hranicí lesa.

Tab. 3: Použitá pravidla a atributy masky vegetace nad horní hranicí lesa

Kategorie	Atributy	Pravidla
střechy a holá půda	Spectral Mean	$G/NIR > 1,28$
stíny	Spectral Mean	$NIR < 62$
(3) vodní plochy	Spectral Mean	$NDVI < 85$
	Spectral Mean	$G/NIR > 1,7$

Pozn. mezi atributy kategorie 3 platí logika "a zároveň"




Obr. 21: Maska vegetace nad horní hranicí lesa

4.4 Objektová klasifikace *Example-based*

V této bakalářské práci byla pro segmentaci použita kombinace všech čtyř spektrálních pásem. Dále byl vybrán segmentační algoritmus *Edge* a spojovací algoritmus *Full Lambda Schedule*. Nastavení parametrů segmentace muselo být takové, aby dvě různé trénovací plochy nezasahovaly do jednoho segmentu. Vzhledem k malým rozdílům v intenzitě mezi jednotlivými druhy trav a po vyzkoušení několika kombinací pomocí náhledového okna byl nastaven *Scale Level* na hodnotu 25 a *Merge Level* na hodnotu 90 (Obr. 22). Při klasifikaci byly zároveň použity texturní parametry snímku. Poté byla na

základě literární rešerše zvolena velikost pohybujícího se okna (*Texture Kernel Size*) 5×5 pixelů.



Obr. 22: Segmentace snímku pro *Example-based* klasifikaci


Po vhodném rozsegmentování snímku následovala samotná klasifikace do stanovených klasifikačních kategorií legendy. Klasifikace pomocí algoritmu SVM proběhla pod předem vytvořenou maskou vegetace nad horní hranicí lesa. Nejprve byly nahrány trénovací plochy nasbírané v terénu, podle kterých byly jako trénovací segmenty označeny všechny, které se pod nimi nacházely. Dále byly vybrány následující spektrální a texturní atributy, na základě kterých byl snímek klasifikován – *Spectral Mean*, *Spectral Max*, *Spectral Min*, *Spectral STD*, *Texture Mean* a *Texture Variance*. Jednotlivé atributy byly vypočítány pro všechna čtyři spektrální pásma a pásmo NDVI. Typ kernelové funkce v algoritmu SVM byl zvolen *Radial Basis*, gama hodnota 0,03, *Penalty Parameter* 100 a *Threshold* 5 %.

4.5 Objektová klasifikace *Rule-based*

Objektová klasifikace pomocí přístupu *Rule-based* proběhla ve dvou krocích. Nejprve byly klasifikovány kategorie (1) kosodřevina a (9) smrk, které se klasifikují snáze, a pod touto maskou byly následně klasifikovány zbylé kategorie legendy.

Segmentace snímku byla provedena na základě pásma NDVI. Opět byl vybrán segmentační algoritmus *Edge* a spojovací algoritmus *Full Lambda Schedule*. Vzhledem k jasným hranicím kleče a smrku byl *Scale Level* nastaven na hodnotu 50 a *Merge Level* na hodnotu 80 (Obr. 23). Pro následnou klasifikaci bylo kromě pásma NDVI, použito

rozdílu modelů DEM a DSM. Prostorové rozlišení tohoto rastru je 1 m, zatímco prostorové rozlišení ortofot je 12,5 cm. Pomocí funkce *Resample* v softwaru ArcGIS 10.2 byla algoritmem *Nearest neighbour* změněna velikost pixelů rastru na 12,5 cm. Nastavení pravidel pro obě kategorie je v tabulce 4.



Obr. 23: Segmentace snímku Rule-based klasifikace pro oddělení kategorie 1 a 2

Tab. 4: Použitá pravidla a atributy pro Rule-based klasifikaci kategorií 1 a 9

Kategorie	Atributy	Pravidla
1	Spectral Mean	$0,15 < \text{rozdíl DEM a DSM} < 0,5$
	Spectral Mean	$\text{NDVI} < 230$
9	Spectral Mean	$\text{rozdíl DEM a DSM} > 0,43$

Pozn. mezi atributy kategorie 1 platí logika "a zároveň"

Pro segmentaci zbylých kategorií legendy bylo zvoleno pásmo GRDI. Opět byl zvolen segmentační a spojovací algoritmus *Edge* a *Full Lambda Schedule*. *Scale Level* byl v tomto případě nastaven na hodnotu 25 a *Merge Level* na hodnotu 90. Pro následnou klasifikaci byla vybrána pásma NDVI, GRDI a SR. Tímto způsobem se však vzhledem ke spektrální podobnosti tříd podařilo oddělit pouze kategorie 4, 5, 6a a 7b, ostatní jsou zahrnuty do jedné. Nastavení jednotlivých pravidel a atributů je v tabulce 5.

Tab. 5: Použitá pravidla a atributy zbylých kategorií legendy

Kategorie	Atributy	Pravidla
4	Texture Mean	$185 < \text{NDVI} < 220$
5	Spectral Mean	$190 < \text{NDVI} < 255$
6a	Spectral Mean	$335 < \text{GRDI} < 413$
	Texture Mean	$\text{NDVI} > 282$
7b	Spectral Mean	$\text{GRDI} > 413$
2a, 2b, 6b, 6c, 7a, 7c, 8	Spectral Mean	$1,12 < \text{SR} < 1,8$
	Spectral Mean	$220 < \text{GRDI} < 335$

Pozn. mezi atributy kategorie 6a a spojené kategorie platí logika "a zároveň"

5 Výsledky

5.1 Hodnocení přesnosti

Nedílnou součástí každé klasifikace je hodnocení její přesnosti. Pro hodnocení přesnosti klasifikací vegetace nad horní hranicí lesa v modelovém území Krkonošského národního parku bylo opět využito softwaru ENVI 5.1 a chybových matic počítaných na základě validačních dat z terénu (*Confusion Matrix Using Ground Truth ROIs*) – sběr dat a rozdělení polygonů na trénovací a validační viz kapitola 4.2.3 a tabulka 1).

Chybová matice je čtvercová a obsahuje tolik řádků a sloupců, kolik je klasifikačních tříd. Ukazuje, do které třídy pixel skutečně patří (sloupce) a do které byl zařazen klasifikační metodou (řádky) (Myint et al., 2008). Správně klasifikované pixely jsou tedy na hlavní diagonále vedoucí z levého horního rohu do pravého dolního rohu. Pixely mimo hlavní diagonálu jsou buď chyby z nesprávného zařazení (*angl.* commission error) udávající počet pixelů, které do dané třídy nepatří nebo chyby z opomenutí (*angl.* omission error), které udávají počet pixelů nezařazených do dané třídy (Exelis VIS, 2014a). Dále je vypočítána celková přesnost, kappa koeficient a nakonec uživatelská a zpracovatelská přesnost pro každou třídu. Uživatelská přesnost je poměr správně klasifikovaných pixelů a počtu pixelů, které do dané kategorie byly zařazeny (řádky). Naproti tomu zpracovatelská přesnost je poměr správně klasifikovaných pixelů a pixelů z kontrolních ploch daných tříd (sloupce) (Exelis VIS, 2014a).

V příloze 2 a 3 jsou uvedeny chybové matice výsledných klasifikací. Uživatelské a zpracovatelské přesnosti jsou spolu s celkovou přesností a kappa koeficientem uvedeny v tabulkách 6 a 7. Klasifikace *Example-based* dosáhla celkové přesnosti 75,97 % s kappa koeficientem 0,73. *Rule-based* klasifikace dosáhla téměř stejné celkové přesnosti (75,45 %), ale nepodařilo se touto metodou od sebe oddělit všechny kategorie legendy. Kappa koeficient byl v tomto případě nižší – 0,68. Bližší charakteristika výsledků jednotlivých klasifikací je dále popsána v diskuzi.

Tab. 6: Přesnosti a kappa koeficient klasifikace Example-based

Kategorie	Zpracovatelská přesnost [%]	Uživatelská přesnost [%]
1	99,50	99,57
2a	72,43	88,97
2b	56,94	71,11
4	69,17	95,89
5	84,10	90,03
6a	66,49	61,19
6b	90,96	40,37
6c	56,35	70,19
7a	40,98	41,57
7b	89,06	58,15
7c	32,00	77,29
8	70,74	50,49
9	62,79	87,75
Celková přesnost [%]		75,97
Celkový kappa koeficient		0,73

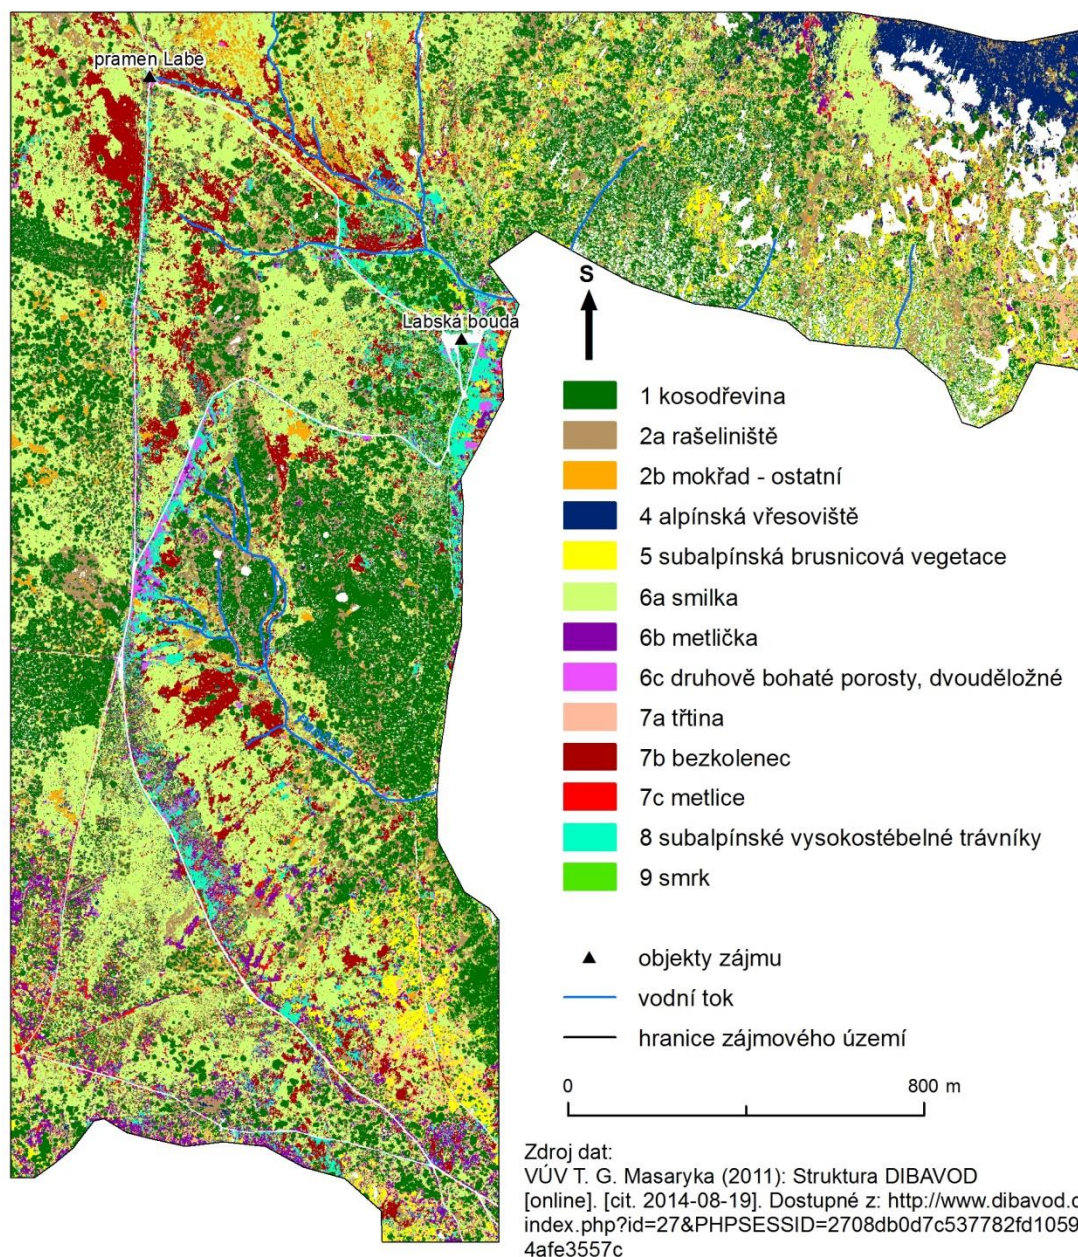
Tab. 7: Přesnosti a kappa koeficient klasifikace Rule-based

Kategorie	Zpracovatelská přesnost [%]	Uživatelská přesnost [%]
1	97,61	93,51
4	59,26	72,03
5	64,36	55,92
6a	62,51	62,11
7b	68,41	60,82
9	84,42	75,62
2a, 2b, 6b, 6c, 7a, 7c, 8	73,01	78,36
Celková přesnost [%]		75,45
Celkový kappa koeficient		0,68

5.2 Grafické výstupy

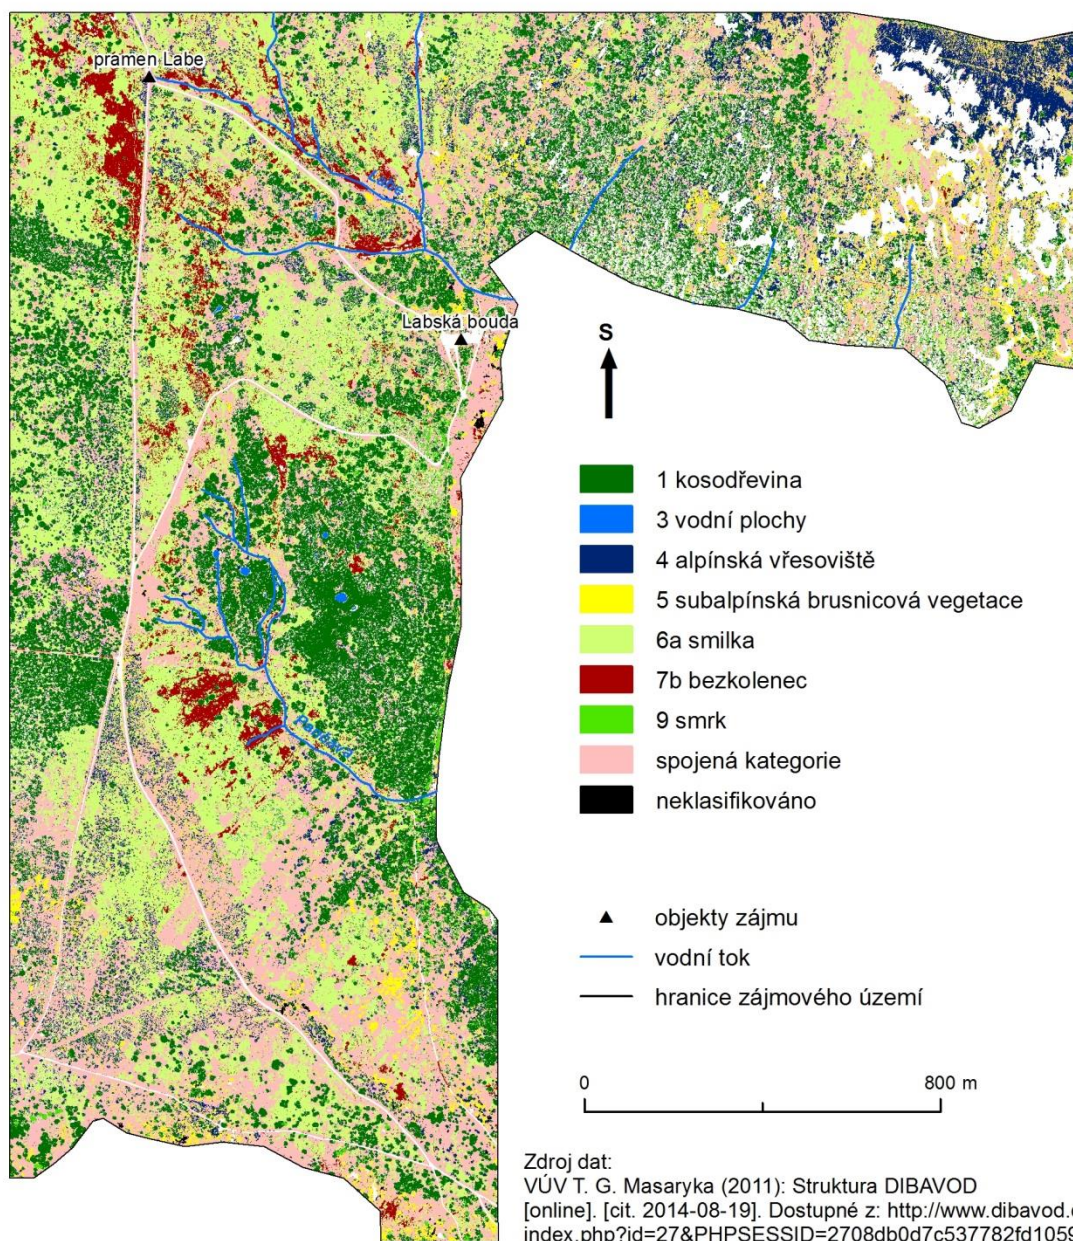
Dalšími výsledky této bakalářské práce jsou dva mapové výstupy výsledných klasifikací vegetace nad horní hranicí lesa. Vizualizace výsledků byla provedena v softwaru ArcGIS 10.2. Na obrázku 24 je výsledek objektové klasifikace pomocí klasifikace *Example-based* s využitím algoritmu SVM a na obrázku 25 *Rule-based* klasifikace.

KLASIFIKACE VEGETACE NAD HORNÍ HRANICÍ LESA NA ÚZEMÍ KRNP V LÉTĚ ROKU 2012



Obr. 24: Výsledek objektové klasifikace pomocí přístupu Example-based

KLASIFIKACE VEGETACE NAD HORNÍ HRANICÍ LESA NA ÚZEMÍ KRNP V LÉTĚ ROKU 2012



Obr. 25: Výsledek objektové klasifikace pomocí přístupu Rule-based

6 Diskuze

Arkto-alpínská tundra je velice heterogenní a druhově velmi bohatá. Především u jednotlivých druhů trav dochází k jejich prolínání a neexistují mezi nimi jasné hranice. Jak je také vidět na grafech odrazivosti vzorků jednotlivých kategorií v kapitole 4.1 (Obr. 17), některé kategorie (např. kategorie 5 a 6c nebo 7a a 8) mají velmi podobný průběh spektrální křivky odrazivosti. Proto se také očekávalo, že nejvíce se mezi sebou budou zaměňovat právě takovéto kategorie. Nakonec to neplatilo však zcela – jedním důvodem tohoto může být i určitá „nespolehlivost“ ukázkových spekter, která byla náhodně vybrána z jednoho vzorku dané kategorie. Spektra byla také pořízena dva roky po pořízení obrazových dat, i když ve stejném vegetačním období, ale určité odlišnosti tu stále mohou být.

Co se týče výsledků klasifikací jednotlivých kategorií, tak podle očekávání dosáhla nejlepších výsledků pomocí klasifikace *Rule-based* kategorie (3) vodní plochy (zpracovatelská přesnost – 99,76 % a uživatelská přesnost – 100 %). Mezi kategoriemi vegetace dosáhla nejlepších výsledků v obou klasifikacích kategorie (1) kosodřevina, která je velmi dobře rozeznatelná i při vizuální interpretaci snímku. V klasifikaci *Example-based* byla její zpracovatelská přesnost 99,5 % a uživatelská 99,57 %. Špatně bylo klasifikováno pouze 532 pixelů z 105 837. Nejvíce jich bylo špatně přiřazeno do kategorií (2a) rašeliniště a (9) smrk. V klasifikaci *Rule-based* byla zpracovatelská a uživatelská přesnost třídy (1) kosodřevina o něco nižší, ale stále velmi vysoká (97,61 % a 93,51 %).

Další dobře rozeznatelnou kategorií při vizuální interpretaci snímku je kategorie (9) smrk. V této kategorii dosáhla lepších výsledků klasifikace *Rule-based*, ve které byly pro stanovení pravidel použity rozdíly modelů DEM a DSM. Zpracovatelská přesnost byla v tomto případě 84,42 % a uživatelská 75,62 %. Špatně klasifikované pixely byly pouze v kategorii 1 (kosodřevina) a spojené kategorii. Použití kombinace multispektrálního snímku s DEM a DSM se ukázala jako vhodná metoda pro přesnější klasifikaci stromů. V klasifikaci *Example-based* se tato kategorie zaměňovala kromě výše jmenovaných i s kategorií 5 (subalpínská brusnicová vegetace).

Po zkušenostech z terénního průzkumu se předpokládalo, že nejvíce se mezi sebou budou zaměňovat podkategorie kategorie 7. Především pak kategorie (7a) třtina

a (7b) bezkolenec, které jsou si velice podobné a na některých lokalitách je botanik od sebe odlišil až po podrobnějším prozkoumání stébla. Jak ale lze vidět na jejich spektrálních křivkách odrazivosti, bezkolenec má výrazně vyšší odrazivost v oblasti blízkého infračerveného pásma než třtina. To může být způsobeno i tím, že na plochách třtiny se mohlo vyskytovat více polehlé stařiny (odumřelé trávy) než u bezkolence.

Nejllepších výsledků dosáhl z kategorií travin právě bezkolenec, který se jako jediný podařilo oddělit i v klasifikaci *Rule-based*. V obou klasifikacích bylo nejvíce špatně zařazených pixelů do kategorie 6a (smilka) a 8 (subalpínské vysokobylinné trávníky) v případě *Example-based* klasifikace respektive spojené kategorie v případě *Rule-based*. Zpracovatelská a uživatelská přesnost *Example-based* klasifikace byla 89,06 % a 58,15 % a klasifikace *Rule-based* 68,41 % a 60,82 %.

Největší rozdíly v uživatelské a zpracovatelské přesnosti byly v kategoriích (6b) metlička a (7c) metlice. Na základě poměru správně zařazených pixelů a celkových pixelů v kategorii byla přesnost klasifikace metličky velmi vysoká – 90,96 %, na druhou stranu byly do této kategorie zařazeny s více než tisíci pixely kategorie 2a (rašeliniště), 5 (subalpínská brusnicová vegetace), 6c (druhově bohaté porosty s velkým zastoupením dvouděložných), 7a (třtina) a 7c (metlice) a uživatelská přesnost tak byla pouhých 40,37 %. Je tedy zřejmé, že kategorie metličky byla trénovacími plochami definována velmi široce a bude potřeba znovu zkontrolovat jednotlivé lokality. Avšak jak je patrné ze spektrálních křivek odrazivosti, tak si je odrazivost metličky velmi podobná s kategoriemi 5, 6c a 7c, což může být také důvod špatného přiřazení těchto kategorií. U kategorie 7c (metlice) se více než polovina validačních pixelů zařadila do kategorie 8 (subalpínské vysokobylinné trávníky) a zpracovatelská přesnost tak byla pouhých 32 %, ovšem v kategorii 8 se do této špatně zařadilo pouhých 244 pixelů z 27 879. Uživatelská přesnost tak byla 77,29 %.

Müllerová (2005) ve své práci klasifikovala metodou řízené klasifikace maximum likelihood část stejného území řešeného v této práci pomocí ortofot s prostorovým rozlišením 1 m. V porovnání s jejími výsledky je sice celková přesnost objektové klasifikace o něco nižší, ale na druhou stranu se podařilo od sebe oddělit mnohem více kategorií, především pomocí algoritmu SVM v klasifikaci *Example-based*. Müllerová dosáhla metodou řízené klasifikace maximum likelihood celkové přesnosti 79 % a stanovila 7 klasifikačních tříd (kosodřevina, společenstva smilky, vysoké trávy

a bylinná společenstva, vegetace podél silnic, silnice, vodní plochy, zamokřená území – rašeliniště). Pokud se tedy podíváme blíže na kategorie Müllerové, které jsou totožné s kategoriemi v této práci, tak metodou objektové klasifikace s použitím algoritmu SVM bylo dosaženo lepších výsledků v kategorii kosodřevina a rašeliniště. Zpracovatelská a uživatelská přesnost byla v případě Müllerové v kategorii kosodřevina 88,4 % a 86,6 %, a v kategorii rašeliniště 69,7 % a 62,2 %.

V porovnání s dalšími citovanými studiemi v kapitole 2.2 (např. Král, 2009; Zagajewski et al., 2005) bylo touto metodou především klasifikováno mnohem více kategorií s uspokojivými výsledky. Použití ortofot s vysokým prostorovým rozlišením v kombinaci s objektovou klasifikací a algoritmem SVM se tedy jeví jako vhodný způsob pro klasifikaci takto heterogenních společenstev.

Při porovnání dvou přístupů objektové klasifikace v této práci, lze říci, že vhodnější a jednodušší způsob je použití algoritmu SVM v klasifikaci *Example-based*. Nicméně pro lepší výsledky a více oddělených tříd v klasifikaci *Rule-based* by mohlo pomoci přidání dalších pravidel, např. texturních parametrů (*Texture Range*, *Texture Variance*) či pravidel sousedství či různá tvarová kritéria. Toto by však vyžadovalo další podrobný a časově náročný terénní výzkum.

7 Závěr

Cílem práce bylo zhodnotit možnosti využití objektově-orientované klasifikace v kombinaci s ortofoty s vysokým prostorovým rozlišením při klasifikaci arкто-alpínské tundry v modelovém území Krkonošského národního parku. Objektová klasifikace byla provedena v softwaru ENVI 5.1, který nabízí dva přístupy klasifikace – *Example-based* a *Rule-based*. Na základě celkové přesnosti klasifikace dopadly oba přístupy téměř stejně (cca 75 %), avšak klasifikací *Example-based* s využitím algoritmu SVM se podařilo klasifikovat všechny kategorie stanovené legendy a ve většině případů také s uspokojivými výsledky. Nejlepších výsledků dosáhly kategorie (1) kosodřevina (99,5 % a 99,57 %), (2a) rašeliniště (72,43 % a 88,97 %) a (5) subalpínská brusnicová vegetace (84,1 % a 90,03 %), naopak nejhorších výsledků dosáhly kategorie (7a) třtina (40,98 % a 41,57 %), (7c) metlice (32 % a 77,29 %) a také (6b) metlička (90,96 % a 40,37 %). Přístup klasifikace *Rule-based* se ukázal jako velmi vhodný při použití kombinace multispektrálního snímku a rastru, který obsahuje výšku vegetace, pro přesnější klasifikaci kategorie smrk.

Dalším cílem bylo také porovnání výsledků klasifikace *Example-based* s algoritmem SVM s výsledky Müllerové (2005) a její metodou řízené klasifikace maximum likelihood. Vstupní data použitá v této práci měla vyšší prostorové rozlišení (12,5 cm) než data Müllerové (1 m). Müllerová tímto způsobem dosáhla vyšší celkové přesnosti klasifikace, nicméně podařilo se jí klasifikovat pouze 7 kategorií, zatímco objektovou klasifikací se podařilo klasifikovat celkem 14 kategorií a kategorie kosodřevina a rašeliniště dosáhly lepší zpracovatelské a uživatelské přesnosti. V kategorii kosodřevina to bylo 99,5 % a 99,57 % oproti 88,4 % a 86,6 %. V kategorii rašeliniště 72,43 % a 88,97 % oproti 69,7 % a 62,2 %.

Použitá literatura

- BLASCHKE, T. (2010): Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, č. 1, s. 2–16.
- CLEVE, C. et al. (2008): Classification of the wildland–urban interface: A comparison of pixel- and object-based classifications using high-resolution aerial photography. *Computers, Environment and Urban Systems*, 32, č. 4, s. 317–326.
- CONGALTON, R. G. (1991): A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37, s. 35–46.
- DOBROVOLNÝ, P. (1998): Dálkový průzkum Země: digitální zpracování obrazu. Brno: Masarykova univerzita, 208 s.
- DVORSKÝ, M. (2009): *AVENELLA FLEXUOSA (L.) Drejer – metlička křivolaká / metluška křivolaká* [online]. [cit. 2014-08-01]. Dostupné z: <http://botany.cz/cs/avenella-flexuosa/>.
- EXELIS VIS (2014a): *Calculate Confusion Matrices (Using ENVI)* [online]. [cit. 2014-08-03]. Dostupné z: <http://www.exelisvis.fr/docs/calculatingconfusionmatrices.html#UseROI>.
- EXELIS VIS (2014b): *Extract Features (Using ENVI)* [online]. [cit. 2014-08-03]. Dostupné z: <http://www.exelisvis.fr/docs/ExtractFeatures.html>.
- FOODY, G. M. a MATHUR, A. (2004): A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42, s. 1335–1343.
- GISAT (200-?): *Klasifikace* [online]. [cit. 2014-02-12]. Dostupné z: <http://www.gisat.cz/content/cz/dpz/zpracovani-dat/klasifikace>
- GITELSON, A. A. et al. (2002): Novel algorithms for remote sensing estimation of vegetation fraction. *Remote Sensing of Environment*, 80, s. 76–87.
- HÁJEK, M. a RYBNÍČEK, K. (2001): Vrchoviště. In: *Katalog biotopů České republiky*. Agentura ochrany přírody a krajiny ČR, Praha, s. 71–76.
- HUANG, C. et al. (2002): An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23, s. 725–749.
- JORDAN, C. F. (1969): Derivation of leaf area index from quality of light on the forest floor. *Ecology*, 50, s. 663–666.
- KOČÍ, M. (2001a): Alpínské trávníky. In: *Katalog biotopů České republiky*. Agentura ochrany přírody a krajiny ČR, Praha, s. 89–91.

- KOČÍ, M. (2001b): Kosodřevina. In: *Katalog biotopů České republiky*. Agentura ochrany přírody a krajiny ČR, Praha, s. 104–105.
- KOČÍ, M. (2001c): Subalpínská vysokobylinná vegetace. In: *Katalog biotopů České republiky*. Agentura ochrany přírody a krajiny ČR, Praha, s. 96–100.
- KRAHULEC, F. a KOČÍ, M. (2001): Alpínská a subalpínská keříčková vegetace. In: *Katalog biotopů České republiky*. Agentura ochrany přírody a krajiny ČR, Praha, s. 91–94.
- KRÁL, K. (2009): Classification of Current Vegetation Cover and Alpine Treeline Ecotone in the Praděd Reserve (Czech Republic), Using Remote Sensing. *Mountain Research and Development*, 29, č. 2, s. 177–183.
- KRNAP (200-?): *Krkonošská arko-alpínská tundra* [online]. [cit. 2014-07-16]. Dostupné z: <http://www.krnep.cz/krkonosska-arkto-alpinska-tundra/>
- KUBÁT, K. et al. (2002): Klíč ke květeně České republiky. Academia, Praha, 928 s.
- LALIBERTE, A. S. et al. (2007): An object-based image analysis approach for determining fractional cover of senescent and green vegetation with digital plot photography. *Journal of Arid Environments*, 69, č. 1, s. 1–14.
- LEVIN, A. a WEISS, Y. (2009): Learning to Combine Bottom-Up and Top-Down Segmentation. *International Journal of Computer Vision*, 81, č. 1, s. 105–118.
- MCMAHAN, J. B. et al. (2003): Fuzzy classification of heterogeneous vegetation in a complex arid ecosystem. In: *Final report: Wildfire effects on rangeland ecosystems and livestock grazing in Idaho*. s. 42–45.
- MÜLLEROVÁ, J. (2005): Use of digital aerial photography for sub-alpine vegetation mapping: A case study from the Krkonoše Mts., Czech Republic. *Plant Ecology*, 175, č. 2, s. 259–272.
- MYINT, S. W. et al. (2008): Comparison of remote sensing image processing techniques to identify tornado damage areas from Landsat TM data. *Sensors*, 8, č. 2, s. 1128–1156.
- MYINT, S. W. et al. (2011): Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 115, č. 5, s. 1145–1161.
- PEJČOCH, D. (2011): Metody řešení problematiky neúplných dat. *Forum Statisticum Slovaca*, 7, č. 7, s. 187–192.
- RANDUŠKA, D. et al. (1983): Barevný atlas rostlin. Obzor, Bratislava, 640 s.
- RESLER, L. M. et al. (2004): Mapping the Alpine Treeline Ecotone with Digital Aerial Photography and Textural Analysis. *Geocarto International*, 19, č. 1, s. 37–44.

- SHA, Z. et al. (2008): Using a hybrid fuzzy classifier (HFC) to map typical grassland vegetation in Xilin River Basin, Inner Mongolia, China. *International Journal of Remote Sensing*, 29, č. 8, s. 2317–2337.
- SOJÁK, J. (1983): Kapesní atlas rostliny našich hor. Státní pedagogické nakladatelství, Praha, 432 s.
- SOUKUPOVÁ, L. et al. (1995): Arctic-alpine tundra in the Krkonoše, the Sudetes. *Opera corcontica*, 32, s. 5–88.
- ŠTURSA, J. (2013): Arktoalpínská tundra Krkonoš. *Živa*, č. 4, s. 171–174.
- VAN DER LINDEN, S., RABE, A., HELD, M., WIRTH, F., SUESS, S., OKUJENI, A., HOSTERT, P. (2014): imageSVM Classification, Manual for Application: imageSVM version 3.0. Humboldt-Universität zu Berlin, Germany.
- VAN DER SANDE, C. J. et al. (2003): A segmentation and classification approach of IKONOS-2 imagery for land cover mapping to assist flood risk and flood damage assessment. *International Journal of Applied Earth Observation and Geoinformation*, 4, č. 3, s. 217–229.
- VAPNIK, V. N. (1998): Statistical learning theory. New York: Wiley.
- YU, Q. et al. (2006): Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering & Remote Sensing*, 72, č. 7, s. 799–811.
- ZAGAJEWSKI, B. et al. (2005): Mapping high mountain vegetation using hyperspectral data. *EARSeL eProceedings*, 4, č. 1, s. 70–78.
- ZHU, G. a BLUMBERG, D. G. (2002): Classification using ASTER data and SVM algorithms;: The case study of Beer Sheva, Israel. *Remote sensing of Environment*, 80, č. 2, s. 233–240.

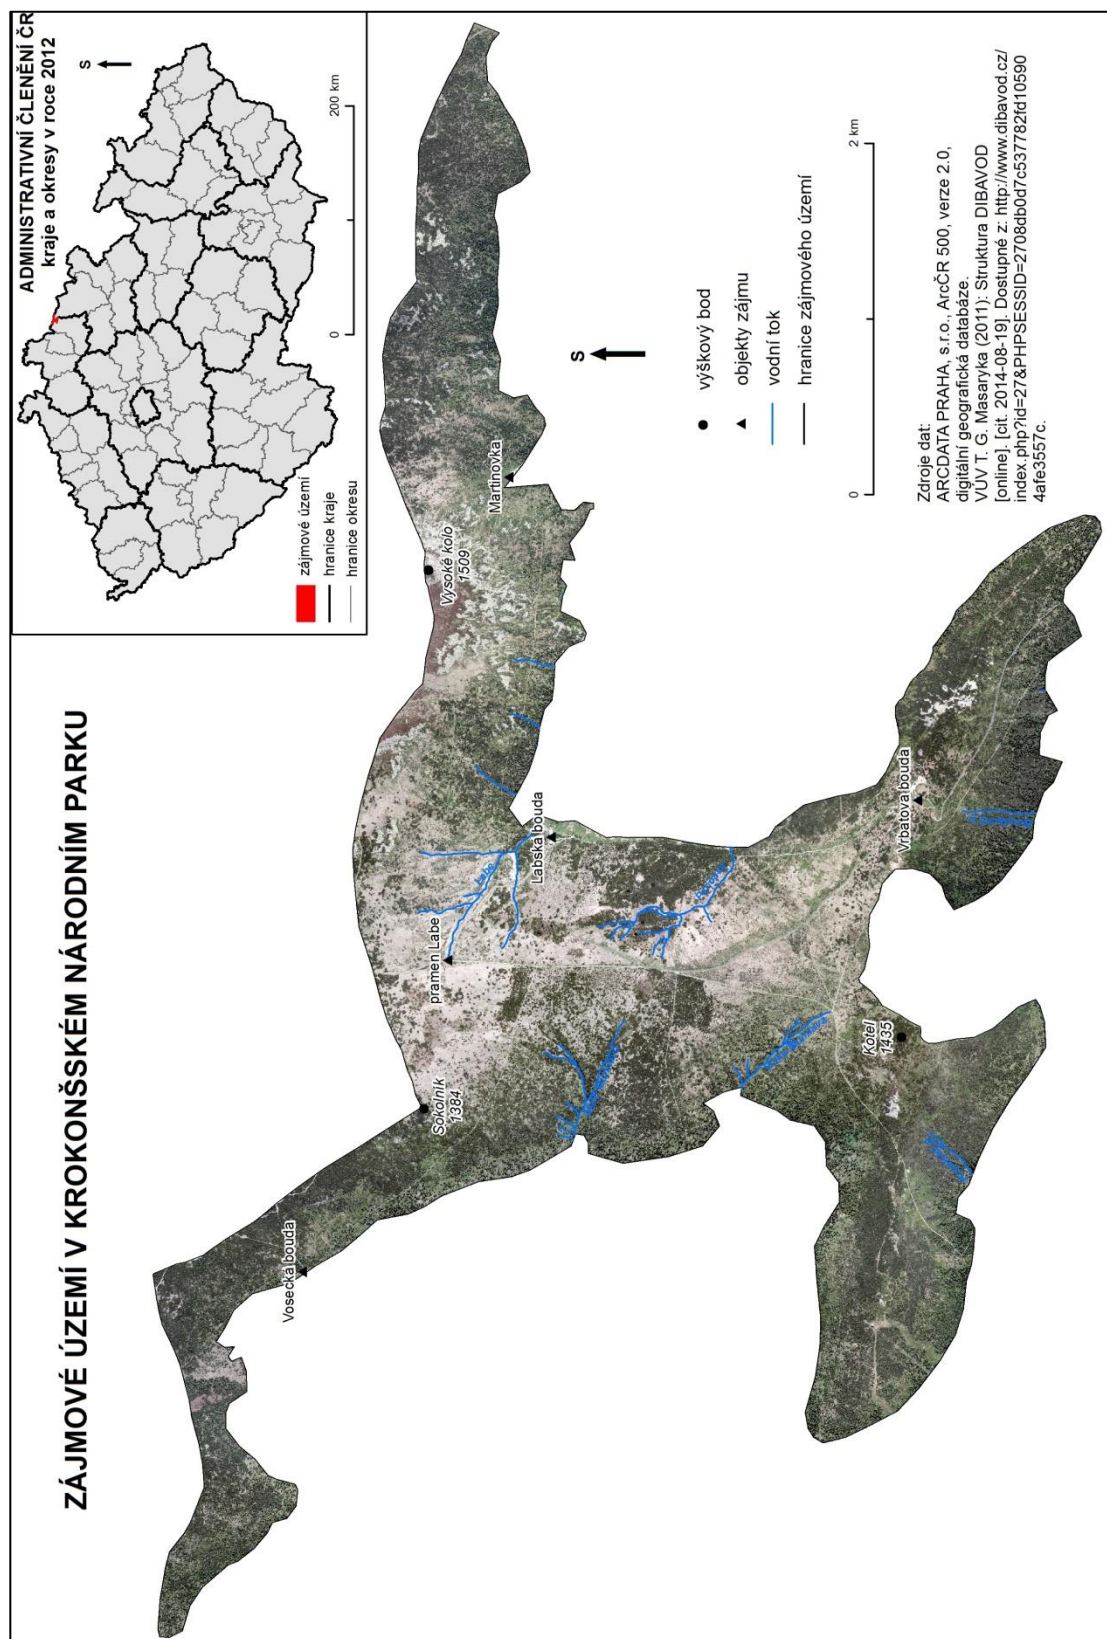
Seznam příloh

Příloha 1: Přehledová mapa zájmového území v KRNAP

Příloha 2: Chybová matice objektové klasifikace *Example-based*

Příloha 3: Chybová matice objektové klasifikace *Rule-based*

Příloha 1: Přehledová mapa zájmového území v KRNAP



Příloha 2: Chybová matice objektové klasifikace *Example-based*

Klasifikovaná data													
Kategorie	1	2a	2b	4	5	6a	6b	6c	7a	7b	7c	8	9
1	105 305	78	0	0	84	0	0	0	0	0	0	0	290
2a	260	43 812	1 799	1 205	48	1 416	0	0	34	383	189	42	55
2b	0	835	4 850	1 102	0	31	0	0	0	0	0	0	2
4	5	905	337	30 675	0	49	0	0	0	20	0	0	0
5	0	226	0	0	22 915	0	124	1 056	380	0	194	204	353
6a	0	8 747	742	10 392	11	37 796	313	18	1 436	1 449	720	144	0
6b	0	2 415	0	0	2 053	566	10 032	3 785	3 399	11	1 613	975	0
6c	0	0	0	0	0	0	61	11 653	0	0	322	4 566	0
7a	0	3 119	0	7	1 558	82	218	791	5 022	189	608	137	349
7b	0	251	329	113	0	16 646	0	17	42	27 220	343	1 845	0
7c	0	90	139	842	104	129	25	194	462	48	7 749	244	0
8	0	14	322	14	153	132	256	3 167	1 480	1 242	12 475	19 722	88
9	267	0	0	0	1	0	0	0	0	0	0	0	1 919
celkem	105 837	60 492	8 518	44 350	26 927	56 847	11 029	20 681	12 255	30 562	24 213	27 879	3 056
													432 646

Příloha 3: Chybová matice objektové klasifikace *Rule-based*

Validační data									
Klasifikovaná data	Kategorie	1	4	5	6a	7b	9	2a, 2b, 6b, 6c, 7a, 7c, 8	celkem
	nezařazeno	1 602	56	56	92	53	234	3 809	5 902
	1	103 303	0	62	35	0	24	7 047	110 471
	4	60	26 283	1 053	0	0	0	9 092	36 488
	5	3	3 005	17 329	159	17	0	10 476	30 989
	6a	0	2 302	0	35 535	7 234	0	12 142	57 213
	7b	0	134	0	11 363	20 907	0	1 973	34 377
	9	813	0	0	0	0	2 580	19	3 412
	2a, 2b, 6b, 6c, 7a, 7c, 8	56	12 570	8 427	9 663	2 351	218	120 509	153 794
	celkem	105 837	44 350	26 927	56 847	30 562	3 056	165 067	432 646